

EFI 法により最適化したセンサ配置を用いた鋼鉄桁橋のベイズ異常検知

Bayesian anomaly detection for a steel plate girder bridge using optimized sensor arrangement by means of the EFI method

尾中貴輝*, 金哲佑†, 五井良直**, 河邊大剛***

Yoshiki Onaka, Chul-Woo Kim, Yoshinao Goi, Daigo Kawabe

*京都大学, 工学研究科社会基盤工学専攻博士前期課程 (〒657-8540 京都府京都市京都大学桂)

†博 (工), 京都大学教授, 工学研究科社会基盤工学専攻 (〒657-8540 京都府京都市京都大学桂)

**博 (工), 京都大学助教, 工学研究科社会基盤工学専攻 (〒657-8540 京都府京都市京都大学桂)

***京都大学, 工学研究科社会基盤工学専攻博士後期課程 (〒657-8540 京都府京都市京都大学桂)

This study aims to investigate the effectiveness of a Bayesian hypothesis-based Bayesian damage detection using sensors arrangement optimized by means of the effective independence (EFI) method. The feasibility of Bayesian anomaly detection is verified using vibration and damage experimental data on an actual steel plate girder bridge. The optimal sensor arrangement and Bayesian anomaly detection for the bridge are also investigated using finite element analysis. Observations demonstrated that it is possible to detect damage and to identify the damage location approximately even with optimally arranged three sensors. In addition, the EFI method was also useful in Bayesian anomaly detection.

Keywords: Bayesian hypothesis test, Optimal sensor arrangement, Vibration-based structural health monitoring, Damage experiment

キーワード: ベイズ仮説検定, 最適センサ配置, 振動構造ヘルスマモニタリング, 損傷実験

1. 序論

平成 26 年度の道路橋定期点検要領の改正に伴って, 全橋梁に対して 5 年に 1 度の定期点検が義務づけられているように, 供用後 50 年以上を経過した橋梁ストックの増加に伴い, 橋梁ストックの安全かつ長期活用のための維持管理の重要性がますます高まっている¹⁾。近接目視による状態の把握が基本とされているが, 目視点検にかかる時間, コストと主観的判断の介入可能性を考慮すると, より効率的で定量的な橋梁の点検手法が求められている。現状は, 従来の目視点検をベースにセンサ情報を活用する過渡期にあると考えられ, 平成 31 年度の道路橋定期点検要領²⁾では, 監視すなわちモニタリングが措置の一つとして新たに加わった。その結果, 目視点検の合理化の観点から, 画像情報に深層学習を適用した点検も盛んに行われている。

一方で, 目視では判断が難しい構造的な性能変化の監視や, 構造特性の長期的な経過観察を目的として, 橋梁にセン

サを設置し, センサから計測されるひずみ, 変位, 加速度などの物理量から構造性能を評価しようとする研究が長年にわたり行われてきた。その中でも, 設置が容易で固定点を必要としない加速度センサで計測される振動に着目した構造ヘルスマモニタリング (Vibration-based Structural Health Monitoring: VSHM) が注目されている。VSHM の考え方は, 損傷による橋梁の見かけ上の剛性低下が要因となり, 橋梁全体の固有振動数, モード形状, 減衰定数といった振動特性が変化することに注目している。関連研究も多数報告されている³⁻¹⁰⁾。

5.2 節に後述するように, あらかじめ固有値解析などの方法で特定の損傷に対する振動モードの感度を検討することは可能である。ただし, 実際の損傷検知においてはどのような損傷がどの位置にどの程度生じるかを事前に予測することが困難であることから, 感度の高い振動モードをあらかじめ特定することが難しい。また, 実測データから推定される振動特性は推定誤差を伴うため, 微小な振動特性の変化から有意な変動を検出するためには煩雑な統計処理が必要となる。このため, 構造物の動的挙動を複数の振動モード情報を包有する統計モデルとし

† 連絡著者 / Corresponding author

E-mail: kim.chulwoo.5u@kyoto-u.ac.jp

て表現し、そのモデルにおける変化の程度を定量化することで、VSHMによる損傷検知が試みられている。たとえば、運動方程式の多変量自己回帰モデルの係数行列^{9,10}やハンケル行列¹²を特徴量とする方法が報告されている。また、特徴量の変化に外れ値解析やパターンマッチングなどの手法を融合することで、振動モニタリングによる橋梁異常検知の可能性についても報告されている^{8,10,12}。

上述のように損傷の位置や規模を事前に予想することが困難であるため、損傷の見落としを避けるためには、構造物の高次モードを含めた複数の振動モードの応答を計測できることが望ましい。その一方で、現実的に設置できるセンサの個数は橋梁管理者の予算規模などの制約を伴う。このことから、少数のセンサで主要な振動モードの情報を最大限収集できるようセンサ配置の最適化が望まれる。モニタリング精度を大きく損なうことなくVSHMシステムのコストを下げることを目的としたセンサ配置最適化の手法として、Kammer¹³は構造物のモード識別のために、センサ配置最適化に着目し、Effective Independence method (EFI 法) を提案した。またEFI法を拡張し、振動情報が乏しい場所をセンサ位置として選ぶ可能性を低減する方法として、Effective Independence Driving-Point Residue method (EFI-DPR 法)¹⁴やEffective Independence Kinetic Energy method (EFI-KE 法)¹⁵など、様々な修正EFIベースのアプローチが提案されている。

本研究では、VSHMにおける現状と要求を鑑み、供用終了後の鋼鉄桁橋で行った損傷および振動実験データを活用し、センサ配置の最適化によるベイズ異常検知の可能性検討を目的とする。具体的には、以下の検討を行う。

- 先行研究¹⁶にて検討されたベイズ異常検知手法の適用性について、実際の鋼鉄桁橋を対象として振動および損傷実験データを用いて確認する。上記手法では運動方程式の多変量自己回帰モデル¹⁷の係数行列を特徴量とし、ベイズ因子 (Bayes Factor: BF)¹⁸による外れ値解析を行う。
 - 多変量自己回帰モデルの係数行列から構造物のモード形状を含む振動特性同定ができる^{10,16,17}点に着目すると、本研究で特徴量として採択する回帰係数行列にEFI法を適用し、センサ配置の最適化が可能であると考え。そこで、本研究の主題である、センサ配置の最適化手法として、構造物のモード形状情報に基づくEFI法^{13,19,20}を用い、センサ配置の最適化によるベイズ異常検知の可能性を検討する。
 - 実用的なモニタリングを考慮すると、有限要素モデル上で最適センサ配置を求め、実橋梁に適用性を検討する必要がある。有限要素解析 (Finite Element Analysis: FEA) による対象橋梁の最適センサ配置とベイズ異常検知について検討を行う。
- 本論文の構成として、第2章には橋梁振動モニタリングによる異常検知法として導入しているベイズ仮説検定

による異常検知法の基本理論を、第3章にはEFI法について簡単に説明する。より詳細な理論展開に関心がある場合は、ベイズ異常検知については文献^{10,18,21}を、EFI法については文献^{13,19,20}を参照されたい。第4章に、実際の鋼鉄桁橋の損傷実験データを用いて最適配置された3つのセンサによるベイズ異常検知の可能性について考察を行う。第5章には、有限要素解析による異常検知の再現について考察する。また、実験で考慮できなかった支間中央部の損傷を有限要素解析でシミュレーションし、最適配置された3つのセンサによるベイズ異常検知の可能性についても考察する。

2. ベイズ仮説検定による異常検知

2.1 運動方程式の多変量自己回帰モデル

橋梁の常時振動について m 自由度の離散加速度時系列が計測されるとし、これらの時系列を要素とする列ベクトル $\mathbf{y}_k \in \mathbb{R}^{m \times 1}$ を考える。ここで k は離散時系列のタイムステップを、 m は観測点の数、つまりセンサの個数を表す。加速度時系列 $\mathbf{y}_k$ は適当なモデル次数 p を用いて次のような多変量自己回帰モデル (Vector Auto-Regressive (VAR) model) で近似できることが知られており、VARの係数行列からモード振動数、モード減衰、モード形状の同定が可能である^{10,16,17}。

$$\mathbf{y}_k = \sum_{i=1}^p \alpha_i \mathbf{y}_{k-i} + \mathbf{e}_k \quad (1)$$

ここで、 $\alpha_i \in \mathbb{R}^{m \times m}$ は i 次の自己回帰係数行列であり、 $\mathbf{e}_k \in \mathbb{R}^{m \times 1}$ は白色ガウスノイズベクトルの時系列である。議論を簡潔にするために、 $\mathbf{W} = [\alpha_1, \dots, \alpha_p] \in \mathbb{R}^{m \times mp}$ とおき、式(1)を次のように変形する。

$$\mathbf{y}_k = \mathbf{W} \{\mathbf{y}_{k-1} \dots \mathbf{y}_{k-p}\}^T + \mathbf{e}_k = \mathbf{W} \boldsymbol{\phi}_k + \mathbf{e}_k \quad (2)$$

ここで $\boldsymbol{\phi}_k \in \mathbb{R}^{mp \times 1}$ は $\mathbf{y}_{k-1}, \dots, \mathbf{y}_{k-p}$ を縦に並べた列ベクトルである。さらに $\boldsymbol{\Sigma}$ をノイズベクトル $\mathbf{e}_k$ の共分散行列とすると、 $\mathbf{y}_k$ の確率密度関数は次のように表される。

$$p(\mathbf{y}_k | \boldsymbol{\phi}_k, \mathbf{W}, \boldsymbol{\Sigma}) = \mathcal{N}(\mathbf{y}_k | \mathbf{W} \boldsymbol{\phi}_k, \boldsymbol{\Sigma}) \quad (3)$$

ここで、 $p(\cdot | \cdot)$ は条件付き確率密度関数を表し、 $\mathcal{N}(\mathbf{x} | \boldsymbol{\mu}, \boldsymbol{\Sigma})$ は期待値 $\boldsymbol{\mu}$ 、共分散行列 $\boldsymbol{\Sigma}$ をもつ多変量正規分布に従う確率変数 $\mathbf{x}$ の確率密度関数を表すものとする。ベイズ定理を用いて目標変数 $\mathbf{y}$ の観測値から回帰係数 $\mathbf{W}$ および回帰誤差の共分散 $\boldsymbol{\Sigma}$ の推定を行う問題を考える。 n 個の目標変数 $\mathbf{y}_1, \dots, \mathbf{y}_n$ と、対応する入力 $\boldsymbol{\phi}_1, \dots, \boldsymbol{\phi}_n$ からなるデータ集合を考え、それぞれ $\mathbf{Y} = [\mathbf{y}_1, \dots, \mathbf{y}_n] \in \mathbb{R}^{m \times n}$ および $\boldsymbol{\Phi} = [\boldsymbol{\phi}_1, \dots, \boldsymbol{\phi}_n] \in \mathbb{R}^{mp \times n}$ としてまとめる。これらのデータが式(3)の分布から独立に生成されたと仮定すると、パラメータ $\mathbf{W}$ および $\boldsymbol{\Sigma}$ について式(4)の尤度関数が得られる。尤度関数から $\mathbf{W}$ 、 $\boldsymbol{\Sigma}$ を推定することになる。

$$p(\mathbf{Y} | \mathbf{W}, \boldsymbol{\Sigma}) = p(\boldsymbol{\phi}_{p+1}) \prod_{k=p+1}^n \mathcal{N}(\mathbf{y}_k | \mathbf{W} \boldsymbol{\phi}_k, \boldsymbol{\Sigma}) \quad (4)$$

2.2 多変量自己回帰モデルの次数決定

本研究では、ベイズ情報量基準(BIC)を用い、VAR モデルの次数を決定する。健全な橋梁の加速度データを参照データ(reference data)、損傷検知対象の橋梁の加速度データをテストデータ(test data)とし、添え字 r は参照データを、添え字 t はテストデータを表す。参照データ Y_r の BIC は次のように表される。

$$BIC = -2\ln p(Y_r | \widehat{W}_r, \widehat{\Sigma}_r) + \left(m^2 p + \frac{m(m+1)}{2}\right) \ln(\Sigma_{i=1}^l n_i - p) \quad (5)$$

ここで、 $\widehat{W}_r$, $\widehat{\Sigma}_r$ は尤度関数 $p(Y_r | W, \Sigma)$ を最大化する最尤推定量であり、 m はセンサ数を、 l は加速度時系列の長さを、 n_i は全てのデータセットの長さを表す。BIC を $p=1$ から計算していき、BIC の値が最小になる p を最適 VAR 次数として採用する。

2.3 ベイズ推論

本論文では、パラメータ W および Σ を総称して回帰パラメータと呼称する。また、2.1 節でも述べた通り、VAR の係数行列 W からモード振動数、モード減衰、モード形状が同定できることから、回帰パラメータ W を特徴量とし、その事後分布を次のベイズ定理を用いて求める。

$$p(W, \Sigma | Y) = p(Y | W, \Sigma) p(W, \Sigma) p(Y)^{-1} \quad (6)$$

ここで、右辺の $p(W, \Sigma)$ は、回帰パラメータの事前確率密度関数である。一方、左辺の $p(W, \Sigma | Y)$ は、既知の観測値を条件として得られる回帰パラメータの事後分布を表す。2.4 節に述べるベイズ仮説検定によるベイズ異常検知のために事後分布に着目する。一般に、事後分布の確率密度関数は事前分布の確率密度関数および尤度関数から一意に定まる。上記の方法で事後分布を算出する過程をベイズ推論と呼ぶ。

ベイズ推論においては共役事前分布と呼ばれる事前分布を仮定することで、事後分布の確率密度関数について閉じた解が得られることが知られている²¹⁾。関連して、数値解析の観点から、供用期間中の損傷検出のための高速計算には、計算効率の点でも共役事前分布が有効であると知られている²¹⁾。式(4)の尤度関数について、回帰パラメータの共役事前分布は次式で定義される行列正規逆ウィシャート分布となることが知られている²²⁾。

$$p(W, \Sigma) = \mathcal{MN}(W | M, \Sigma, L^{-1}) \mathcal{IW}(\Sigma | \Psi, \nu) \quad (7)$$

ここで $\mathcal{MN}(W | M, \Sigma, L^{-1})$ および $\mathcal{IW}(\Sigma | \Psi, \nu)$ はそれぞれ行列正規分布および逆ウィシャート分布に従う確率密度関数であり、次のように定義される。

$$\mathcal{MN}(W | M, \Sigma, L^{-1}) = \frac{(2\pi)^{-(mp \times m)/2} |L^{-1}|^{-m/2} |\Sigma|^{-mp/2}}{\times \exp\left\{-\frac{1}{2} \text{tr}[L(W - M)^T \Sigma^{-1}(W - M)]\right\}} \quad (8)$$

$$\mathcal{IW}(\Sigma | Q, \nu) = 2^{-\nu m/2} \Gamma_m\left(\frac{\nu}{2}\right) |Q|^{\nu/2} |\Sigma|^{-(\nu+m+1)/2} \times \exp\left\{-\frac{1}{2} \text{tr}[Q \Sigma^{-1}]\right\} \quad (9)$$

式(7), (8), (9)のパラメータ $M \in \mathbb{R}^{m \times mp}$, $L \in \mathbb{R}^{mp \times mp}$, $Q \in \mathbb{R}^{m \times m}$ および $\nu \in \mathbb{R}$ は事前分布の形状を決定する超パラメータ (Hyperparameter) という。事後分布の確率密度関数は次のように表されることが知られている²¹⁾。

$$p(W, \Sigma | Y) = \mathcal{MN}(W | M', \Sigma, L'^{-1}) \mathcal{IW}(\Sigma | Q', \nu') \quad (10)$$

ただし、式(10)の超パラメータ M' , L' , Q' および ν' は次のように算出される。

$$L' = L + \sum_{k=p+1}^n \phi_k \phi_k^T \quad (11)$$

$$M' = \left(ML + \sum_{k=p+1}^n y_k \phi_k^T\right) L'^{-1} \quad (12)$$

$$\nu' = \nu + n - p \quad (13)$$

$$Q' = Q + Y \sum_{k=p+1}^n y_k y_k^T + MLM^T - M' L' M'^T \quad (14)$$

式 (11) から式 (14) で示される超パラメータは、観測データを用いて逐次更新することができるが、逐次アルゴリズムの最初のステップでは、観測値が利用できない。したがって、未知の回帰パラメータの事前分布として、いわゆる非情報の事前分布を採用することが一般的あり、無情報事前分布を採用する²³⁾。逐次更新の最初のステップで無情報事前分布を表すために、超パラメータの初期値を $L = \mathbf{0}$, $\nu = 0$, $Q = \mathbf{0}$ とする。

2.4 ベイズ因子を用いたベイズ仮説検定

本研究のベイズ仮説検定は、尤度関数の比として定義されるベイズ因子を評価することにより行われる。 Y を観測データセット、 $\theta (= (W, \Sigma))$ を回帰パラメータとすると、仮説 H_k の尤度関数は次のように生成される。

$$p(Y | H_k) = \int p(Y | \theta, H_k) p(\theta | H_k) d\theta \quad (15)$$

ここで、 $p(Y | \theta, H_k)$ と $p(\theta | H_k)$ はそれぞれ仮説 H_k の条件下での尤度関数と事前分布を表す。仮説 H_k 下での事後分布はベイズ定理より次のように表される。

$$p(H_k | Y) = p(Y | H_k) p(H_k) p(Y)^{-1} \quad (16)$$

仮説 H_k として二つの仮説、帰無仮説 H_0 と対立仮説 H_1 を定義する。帰無仮説 H_0 として「観測値の従う統計的モデルが健全な状態の橋梁と同一である。」とし、対立仮説 H_1 の事前分布をモデル化することは困難を伴うため、ここでは便宜的に「観測値の従う統計的モデルについて事

前情報が不確かである。」とする。式(16)より得られるそれぞれの仮説での事後分布の比（ベイズ因子）をとると次のように表される。

$$\frac{p(H_1|Y)}{p(H_0|Y)} = \frac{p(H_1)p(Y|H_1)}{p(H_0)p(Y|H_0)} \quad (17)$$

式(17)より事後分布の比は事前分布の比と尤度関数の比で表すことができ、帰無仮説 H_0 と対立仮説 H_1 が起こる確率が等しいと仮定する。つまり $p(H_0) = p(H_1)$ とすると、事後分布の尤度関数の比で表す事ができる。すなわち、ベイズ因子が得られたデータセット Y が帰無仮説 H_0 と対立仮説 H_1 のどちらに従っているかを評価する指標になる。既往研究¹⁸⁾においては、式(18)に示すように、ベイズ因子を自然対数のスケールで捉え、 $2\ln B$ が10よりも大きい場合は帰無仮説を棄却する根拠が「非常に強い」とのエビデンスの強さを示している。本研究ではこの考えを踏襲して用いる。

$$BF = 2\ln B = 2\ln \left(\frac{p(Y|H_1)}{p(Y|H_0)} \right) \quad (18)$$

ベイズ因子 (BF) を表す式(18)の Y が、複数のセンサから得られる時系列 $Y = [y_1, \dots, y_n]$ の場合、全てのセンサ情報に基づくベイズ因子になることから、グローバルベイズ因子 (Global Bayes Factor: GBF) と呼ぶ。また、式(17)の Y の代わりに、 j 番目センサの時系列 ($y^j = [y_1, \dots, y_n]$) を考慮すると、 j 番目センサ情報に基づくベイズ因子になることから、ローカルベイズ因子 (Local Bayes Factor: LBF) と呼ぶ。LBF はセンサごとに計算されることから、異常箇所に近いセンサの LBF は特に大きくなることが予想される。そのため大まかな損傷位置の推定に利用できる。

3. センサ配置の最適化

2.1 節より、多変量自己回帰モデルの係数行列には構造物のモード形状を含む振動特性情報が含まれる。そのため、EFI 法で定める最適センサ配置を、回帰パラメータ W を特徴量とする異常検知にも適用できると考える。

EFI 法においては、まず計測値から推定されたモード形状ベクトルについて、ノルムが1になるように正規化を行う。次に、それらを各列に並べたモード形状行列 Φ を用いて最適センサ配置を求める。EFI 法を適用する際には3つの項目を事前に設定する必要がある。1つ目はモード形状行列 Φ を算出する節点の数と箇所の設定を行うことである。すなわち、モード形状を表現するために用いられる参照点の数と配置を事前に決定する。2つ目は対象とするモードを事前に決めておくことである。3つ目は最終的に設置しておくセンサの数 N_0 を予め決めておくことである。なお、最終的に決定されるセンサ数 N_0 は対象とするモード形状の数よりも少なくなってしまうことに留意する¹⁹⁾。関連して、最適配置されたセンサによる異常検知の妥当性は、最適化に用いた振

動モードに損傷が影響を及ぼす場合に限定される点に留意する必要がある。例えば低次モードの振動に影響するような重大な損傷を見逃さないという観点でモニタリングを実施するならば、低次モードのみを対象としてセンサ数と配置を検討するという運用方法が考えられる。あるいは、予算的に余裕があり早期発見や損傷位置の特定という観点でモニタリングを実施するならば、ねじれモードやより高次のモードまでを考慮できるようセンサ数とその配置を検討する必要がある。以上のように、何を目的にしてモニタリングを行うのかは橋梁の規模や管理者の予算規模によってさまざまであり、本論文で論じた最適化手法に加えて多岐に渡る条件を考慮する必要がある。一例として本論文では、後述するように桁橋の局所的な曲げ剛性の変動を検知する目的で、曲げ振動モードを対象とした最適化を検討している。

EFI 法は、式(19)に示すフィッシャー情報量行列 (Fisher Information Matrix: FIM) F に基づき、FIM の行列式を最大化するセンサ配置の推定手法である。式(19)に示すとおり、FIM は、モード形状行列とその転置行列の積として定義される。

$$F = \Phi^T \Phi \quad (19)$$

FIM は対称的であり半正定値行列(positive semidefinite matrix)である。さらに、モード形状ベクトルが線形独立であれば、FIM はフルランクであり、ランクは対象のモード形状の数に等しい¹⁹⁾。FIM の行列式は、モード形状の計測点におけるモード応答の空間的な独立性およびモード応答の振幅の相対的な大きさを定量化する。このため、FIM の行列式が最大となるセンサを残して、センサ数を1つずつ減らしていき、これを繰り返すことで、対象とするモード応答を計測するうえで最適なセンサ配置が得られる。

このセンサ選択は式(20)に示す直行射影行列 E に基づいて決定される。

$$E = \Phi F^{-1} \Phi^T \quad (20)$$

行列 E の対角成分 E_{ii} はモード形状行列 Φ の i 番目の成分の影響力を表している。FIM の行列式を最大化するために、最小の値を持つ E_{ii} を除外する (式(21)参照)。つまり、除外された i 番目の要素は、対象モードへの影響が最も少ないセンサとして取り除かれる。

$$\det(F) = \det(F_0) (1 - E_{ii}) \quad (21)$$

ここで、 F_0 は元々の FIM を、 F は i 番目のセンサを取り除いたあとの FIM を表す。したがって、式(21)が示すようにモード形状行列 Φ から1行取り除くごとに、FIM 行列式は減少していく。このようにして、事前に決めたセンサ数 N_0 になるまでセンサ数を減らし、最適なセンサ配置を決定していく。




図-1 対象橋の諸元，加速度センサ位置と人工損傷。

4. 鋼鈹桁橋の振動計測と異常検知

4.1 鋼鈹桁橋の振動および損傷実験

単純鋼鈹桁橋梁を対象に、損傷度合いや損傷位置推定に基づく損傷検知の検討を行うことを目的として人工的な損傷を与え、各損傷シナリオにおいて車両走行実験を行った²⁴⁾。対象橋梁は1957年に架設され、2017年に供用を終了しその後撤去された、全橋長40.5m、有効幅員4.0m、桁高2.0mの鋼単純2主鈹桁橋である。対象橋梁の写真、寸法、センサ配置、損傷を図-1に示す。損傷導入以前の橋梁の状態を以後INTと記す。

損傷箇所は、図-1に示すようにAb1支承の上流側に近い桁端部である。損傷シナリオについては、桁端部の支承部付近における下フランジからウェブプレートまで進展するき裂を模擬し、ガス切断器を用いて二段階に分けて損傷を導入する。ガス切断をする際、意図せぬき裂の進展を防ぐために、ウェブプレートに導入するき裂の末端にストップホールを設置した。支承部から180mm離れた位置の下フランジに貫通き裂を導入した損傷シナリオを「DMG1」、DMG1シナリオの損傷位置からさらにウェブプレートの高さ200mmまで斜めにき裂を導入した損傷シナリオを「DMG2」とする。支承部についてはAb1側が線支承、Ab2側がピボット支承となっている。

車両走行による橋梁の鉛直方向の加速度応答を計測するために走行振動実験を行った。走行車両は、総重量約32kNのハイエース（TOYOTA製）である。走行速度約20km/hで振動実験を実施し、各走行による試行数はそれぞれ、INTで60回、DMG1で32回、DMG2で30回である。走行方向は、Ab1からAb2を往復しており、片道を1試行とする。サンプリング周波数は200Hz、データ長は15秒（車両走行による強制振動は約5秒で走行後の自由振動は約10秒）である。また加速度センサは、高感度加速度計ARS-10A（東京測器研究所）を用い、データロガーとして加速度応答の計測にはマルチレコーダTMR-200シリーズ（東京測器研究所）を用いた。

加速度センサは上流側（A1からA5）と下流側（A6からA10）それぞれの主桁下フランジ部に等間隔となるように5か所ずつ計10か所に設置した。計測した加速度時系列の例を図-2(a)に示す。


橋梁に取り付けた加速度センサにより観測された加速度情報から、Stochastic Subspace Identification (SSI)²⁵⁾による振動特性同定を行った。固有振動数の平均値および変動係数を表-1に示す²⁴⁾。また、各損傷シナリオの計測回数分の振動モード形状をそれぞれ正規化した後、各計測点の平均値からなる平均化されたモード形状を求めた。各損傷シナリオにおいて同定されたモード形状を図-2(b)に示す。さらに、INTのモード形状に対するDMG1とDMG2のMAC値も表-1に示す。

振動特性から、損傷の進行に伴い固有振動数の変化が確認できる。曲げ2次、曲げ3次モードの固有振動数は


表-1 同定振動特性

Mode		INT	DMG1	DMG2
1 st bending	Freq. (Hz)	3.15	3.25	3.28
	CV	0.013	0.011	0.006
	MAC	-	1.000	0.999
2 nd bending	Freq. (Hz)	9.53	9.24	8.85
	CV	0.009	0.005	0.005
	MAC	-	0.993	0.975
3 rd bending	Freq. (Hz)	21.87	21.87	21.60
	CV	0.005	0.004	0.003
	MAC	-	0.998	0.991

Freq.: Frequency, CV: Coefficient of Variation,
MAC: Modal Assurance Criterion



(a) 加速度応答



(b) 同定曲げ振動モード

図-2 損傷導入前の状態(INT)の加速度応答と
同定曲げ振動モード。

損傷の進行とともに低下する傾向が確認できる。特に曲げ2次モードの固有振動数が損傷後に大きく低下しており、DMG1、DMG2の順にそれぞれ0.29Hz、0.68HzだけINTから低下している。損傷を導入することにより、桁の見かけ上の剛性が低下したことで固有振動数が低下したと考えられる。一方、曲げ1次モードの固有振動数に関しては、損傷導入後に上昇する結果となった。損傷に起因する剛性低下による振動数の低下とは異なる傾向を示している。本実験で同定された曲げ1次モードの固有

振動数の変化は、損傷による桁の剛性低下以外に、計測時の温度変化の影響が想定される。上記についての詳細は文献 26) を参照されたい。また先行研究にて静的載荷試験結果から、支承部の変状の影響について考察している。詳細は文献 24) を参照されたい。

4.2 最適センサ配置とベイズ異常検知

対象橋の損傷に伴う振動特性の考察から、損傷に対する感度が振動モードによって異なることがわかる。しかしながら、前述の通り、損傷に敏感な振動モードを事前に決めるのは簡単ではない。そのため、複数のモードの振動情報を含む多変量自己回帰モデルの係数行列を特徴量とし、ベイズ因子による異常判断を行う。また、センサ数による異常検知への影響についても検討を行う。

(1) 全ての加速度センサ情報によるベイズ損傷検知

10 個全ての加速度センサのデータを用いて計算した BF について考察する。まず、式(5)の BIC より最適 AR 次数を検討した結果、図-3 に示すように、 $p=88$ で BIC が最小になっており、 $p=88$ を最適 AR 次数とする。

$p=88$ を採用し求めた GBF と LBF を、それぞれ図-4(a)と 4(b)に示す。各プロットは各走行時の観測値から算出される BF を示す。図-4(a)と 4(b)の縦軸は、式 (18) の BF の大きさを表しており、横軸は各損傷シナリオの試行を表す。また、BF の閾値を 0 としており赤線で表示されている。BF が閾値を上回っていれば帰無仮説を棄却する根拠が「強い」と解釈する。また、CV は交差検証 (Cross Validation: CV) を表しており、データを訓練集合とテスト集合に分けて検証を行い、データの妥当性を検証する手法である²¹⁾。本研究では、一個抜き交差検証 (Leave-One-Out Cross-Validation: LOOCV)²¹⁾を用いている。これはデータから 1 つの事例だけを抜き出して、テスト事例とし、残りを訓練集合とする。これを全事例が 1 回ずつテスト事例となるよう検証を繰り返すものである。図-4 より INT のデータに関して LOOCV を行い、GBF を全て計算した結果、異常なデータが含まれていないことが分かる。

次に、各損傷シナリオ (DMG1 と DMG2) の GBF をみる (図-4(a)) と、INT は全て閾値を下回っており帰無仮説に従っている。すなわち INT の状態と大きく変わらないと状態であると判断できる。DMG1 と DMG2 はどちらも閾値を上回っており、帰無仮説を棄却する根拠が強い、すなわち異常があると判断する。さらに、DMG1 よりも DMG2 の方が GBF の値が大きいことから損傷度合いが大きいほどベイズ因子が大きくなることが分かる。図-4(b)に示す LBF についても、どのセンサでも INT では閾値を下回っている。DMG1、DMG2 について各センサの BF を見ると、損傷に近いセンサ A1 と A6 が他のセンサの BF と比較して最も大きな値を示している。このことから LBF の値の大きさから大まかな損傷位置の推

表-2 EFI 法適用により外されるセンサと残されるセンサのフィッシャー情報量行列(FIM)の行列式

N_0	$N_0=10$	$N_0=9$	$N_0=8$	$N_0=7$
外されるセンサ	-	A7	A9	A2
det(F)	109.7	86.8	67.3	47.6
N_0	$N_0=6$	$N_0=5$	$N_0=4$	$N_0=3$
外されるセンサ	A4	A1	A8	A5
det(F)	33.4	20.1	11.4	6.2

det(F): フィッシャー情報量行列(FIM)の行列式






図-3 BIC による最適 AR 次数の決定 ($p=88$)。



(a) グローバルベイズ因子 (GBF)



(b) ローカルベイズ因子 (LBF)

図-4 全ての加速度センサを用いる際のベイズ因子。

定が可能であると言える。逆に、損傷から遠く離れたセンサから算出された LBF では、損傷位置を推定しにくい場合があると考えられる。

(2) センサ数減少によるベイズ因子の変化

EFI 法を用いた最適センサ配置を行い、配置されたセ






図-5 $N_0 = 3$ の条件での最適センサ配置 (INT 状態).



(a) 全てのセンサ (A1 から A10)



(b) 最適配置センサ (A3,A6,A10)


図-6 異なるセンサ数による加速度特異値スペクトル (SVS)曲線 (INT 状態).

センサ情報による損傷検知を行う。まず、対象橋梁の基準状態である INT の最適センサ配置を調べる。前提条件として、図-2 に示す曲げ 1 次から曲げ 3 次までの 3 つの振動モードを検討対象モードとし、センサ数 $N_0 = 3$ とする。EFI 法を適用するときのセンサ数 N_0 と最適配置から外れるセンサ番号を表-2 にまとめる。


表-2 の見方について簡単に解説する。目標の $N_0 = 3$ のセンサ配置まで、センサ 10 個から、最適センサ配置以外のセンサを一つずつ減らしていく。例えば、センサ 9 個配置 ($N_0 = 9$) には A7 が外されるセンサとなり、残されるセンサ (A1,A2,A3,A4,A5,A6,A8,A9,A10) によるフィッシャー情報量行列(FIM)の行列式は 86.8 である。 $N_0 = 8$ の場合は A9 を、 $N_0 = 7$ の場合は A2 を外すことになる。

このようにしてセンサ配置を行うと、 $N_0 = 3$ の場合は A5 を外すことになり、図-5 に示すように「A3, A6, A10」が残る。そのときの FIM の行列式は 6.2 になった。

比較のために、恣意的にセンサ「A2, A4, A8」を配置する例を考える。「A2, A4, A8」のセンサ配置による FIM の行列式の値は 0.6 であり、EFI 法による最適センサ配置



(a) GBF



(b) LBF

図-7 $N_0 = 3$ の最適センサ配置 (A3, A6, A10) のときの GBF と LBF.




図-8 $N_0 = 3$ の最適センサ配置 (A3, A6, A10) と恣意的に配置したセンサによる GBF.

「A3, A6, A10」の FIM 行列式の 1/10 になる。他の例として、恣意的にセンサ「A1, A5, A8」を配置するときの FIM の行列式の値は 2.6 になる。いずれも最適センサ配置の「A3, A6, A10」の FIM の行列式の値 6.2 より小さいことがわかる。

本研究で検討する曲げ 3 次モード振動数までの PSD の卓越振動数は、センサ数の違いによる影響は微弱であるが、PSD のパワーには変化をもたらす。特徴量として採用する VAR 係数は PSD のパワーとも関連があり^{10,17)}、センサ数の違いによる PSD への影響を確認するために特異値スペクトル (SVS: Singular Value Spectrum) に着目する。 $N_0 = 10$ のときの特異値スペクトル (SVS: Singular Value Spectrum) 曲線と $N_0 = 3$ の最適センサ配置のときの




図-9 対象橋梁のFEモデルと損傷模擬.

SVS 曲線をそれぞれ、図-6(a)と(b)に示す。 $N_0 = 3$ の最適配置センサの第1特異値(1st SV)の卓越振動数(図-6(b))をみると、 $N_0 = 10$ のSVS(図-6(a))に比べて、10dB程度パワーが弱く、ノイズが強い場合は振動特性の同定精度が悪くなる可能性があることが分かる。以上の検討を踏まえて、EFI法によるセンサ配置を用いてベイズ損傷検知を行う。

EFI法で求めた最適センサ配置でベイズ損傷検知が可能かを検討する。また、他の恣意的なセンサ配置(「A2, A4, A8」と「A1, A5, A8」)のときのBFとの比較・検討を行う。まず、EFI法で求めた最適センサ配置(「A3, A6, A10」)におけるGBFとLBFをそれぞれ図-7(a)と(b)に示す。図-7(a)のGBFを見ると、DMG1とDMG2の損傷シナリオともにBFが閾値を越えており、センサ10個配置と同様(図-4(a))に帰無仮説を棄却する根拠が強く異常の可能性が高いと判断できる。DMG1のBFに比べDMG2のBFが大きいことから、損傷度合いの把握も可能であることが分かる。また、図-7(b)のLBFを見ると、最も損傷に敏感なセンサは、損傷位置に最も近いA6であった。

以上より、 $N_0 = 3$ の最適センサ配置でも、損傷度合いの把握のみならずLBFに着目することで大まかな損傷位置の推定が可能であることが分かる。

また、図-5に示した「A3, A6, A10」を用いて計算されるGBFが最も損傷に敏感な配置であることを確認するために、他のセンサの組み合わせ(「A2, A4, A8」と「A1, A5, A8」)と最適配置(「A3, A6, A10」)におけるGBFの比較を行う。

図-8に上記のセンサ3個の組み合わせのGBFを示

す。ここで、図-8のGBFは各損傷シナリオ(INT:60試行, DMG1:32試行, DMG2:30試行)の平均値を用いている。各組み合わせのGBFの平均値を比較すると、DMG1とDMG2の損傷シナリオ共に、EFI法で求めた最適センサ配置である「A3, A6, A10」のセンサ配置が最も損傷に敏感な配置であった。また、モード形状の情報を用いたセンサ配置法であるEFI法は、ベイズ損傷検知にも適用可能であることが分かる。

5. シミュレーションによる最適センサ配置と異常検知

5.1 有限要素モデル

実橋梁に導入した桁端部の模擬き裂とベイズ損傷検知を再現するため、DIANA10.5²⁷⁾を用いて、対象橋梁のFEモデルを構築する。構築した解析モデルを図-9に示す。対象橋梁の設計図面資料の入手が困難であったため、本研究では、定期点検時の報告資料と現地での寸法測定、実験時の計測結果に基づきFEモデルの構築を行う。対象橋梁はコンクリート床版、主桁、横桁、対傾構、鉛直補剛材、水平補剛材で構成されている。

モデル化にあたり、対象橋梁の構成されている部材のうち、コンクリート床版、主桁、鉛直補剛材、水平補剛材はシェル要素、横桁と対傾構ははり要素を用いる。部材間への結合は、全てマージ機能(剛結)を用いた。材料特性について、コンクリート床版に対しては鉄筋コンクリートを、それ以外の部材に対しては鋼を採用する。比重は鋼と鉄筋コンクリートでそれぞれ7.85, 2.40として、材料特性は、材料試験結果に基づき、弾性係数はそれぞれ200GPa, 28.1GPa、ポアソン比はそれぞれ0.27, 0.20と




図-10 模擬損傷の導入シナリオ。


する。上記のように、主桁の補剛材や対傾構を含めて、橋梁の重量への影響が懸念される二次部材はシェル要素および梁要素を用いて概ねモデル化されている。なお、各々の二次部材の剛性および重量については主桁と同様に構造用鋼材の材料特性を用い、現場実験の際に計測された寸法を断面諸元として与えてモデル化した。

高欄は鋼製であり高欄有無による固有値解析結果、振動特性への影響は微小であったため、本解析では考慮していない。またアスファルト舗装の質量は床版の追加質量として考慮しているが、真夏の実験であったため剛性への影響は無視した。


境界条件については、先行研究²⁴⁾にて検証された実験時の桁端部の橋軸方向の変位量を考慮して設定する。対象橋梁はAb1側に線支承、Ab2側にピボット支承をもつが、上記先行研究においては車両の通過に伴うたわみおよび温度変化による伸縮の双方でAb2側のみが変形していることが確認された。このことから、Ab1支承は稼働支承として機能しておらず、Ab2側のピボット支承（図-1のAb2参照）が片持ち梁のように変形することで橋梁のたわみおよび伸縮に追随していることが確認された。このためモデル化においては、Ab1側の支承部を固定とし、Ab2側の支承部の挙動を簡易的に表現するために、ローラー支承に橋軸方向に弾性ばねを導入する。

橋軸方向の見かけ上のばね定数の同定にあたり、FEモデルのキャリブレーションにはCross Entropy (CE) 法²⁸⁾を用いる。既往の研究²⁰⁾より、ばね定数はINTでは $5.05 \times 10^7 \text{ N/m}$ と同定された。構築したFEモデルの固有値解析における、曲げ1次から曲げ3次までの固有振動数はそれぞれ3.18Hz, 9.63Hz, 22.28Hzであり、表-1に示すINT状態の実測振動数と概ね一致することが分かる。


実験で導入した模擬き裂については、FEモデルの要素を取り除くことで模擬し、き裂幅は、実際に導入した模擬き裂と同じ位置に幅5mmでモデル化する。実橋梁において損傷度は3段階で定義されているが、FEモデルでは、進展する損傷に対してBFがどのような影響を受けるかを検討するため、INTからDMG1まで2段階、DMG1からDMG2までの2段階の、INTを含めた5段階で定義した。図-10に示すように下フランジやウェブプレート



(a) 曲げ1次振動数と GBF



(b) 曲げ2次振動数と GBF



(c) 曲げ3次振動数と GBF

図-11 き裂長さによる曲げ振動数と GBF の変化。

へ損傷を導入する際に元の損傷の1/2の長さずつ与えていく。

VAR モデルを同定できる加速度応答をシミュレートすることが、本研究のFEAの主な目的である。そのために、FEAの動的応答解析では、実橋梁の車両—橋梁連成振動解析、任意の白色雑音を入力した動的応答解析や、ある箇所への衝撃加振による動的応答解析などが考えられる。また、車両—橋梁連成振動の代わりに、車両からの外部入力を簡略かし、汎用プログラムが利用できる比較的取り扱いが容易な解析方法が提案されている²⁹⁾。本研究では、実橋での車両走行実験を模擬した動的応答解析を行う。ただし、実橋梁の車両—橋梁連成振動の再現が目的ではないため、車両—橋梁連成解析ではなく、以下の簡易解析を行う。

実橋梁実験の32KNの車両重量を車両走行方向に沿っ

て左右2点を16kNずつの荷重を与え、FEモデルの床版を橋軸方向に1000点を0.005s毎に叩き車両走行を模擬した。これは、実橋実験の車両走行時間が約5秒、自由振動時間が約10秒、サンプリング周波数200Hzであったことを勘案している。ベイズ損傷検知に用いる多くのサンプルを作成するために、この載荷荷重に対して±100Nのランダム変数を加えた。橋梁の加速度応答は実橋梁のセンサ位置と同じ節点の加速度に着目する。また、動的応答解析ではレイリー減衰を用い、実橋梁から得られた固有振動数、減衰比から算出して適用する。具体的には、同定した曲げ1次と2次の振動数（それぞれ、3.15Hzと9.53Hz）と減衰比（それぞれ0.0018と0.010）²⁴⁾を利用する。

ただし、既往の研究²⁶⁾によると、実橋梁ではDMG1導入の際にINTに比べて約10°Cの温度上昇により支承部の性状変化があり、その影響で振動特性が変化したことが報告されている。その温度上昇の影響については、今回のFEAでは考慮していない。また、前述とおり、損傷下での振動データをシミュレーションすることを目的として、車両走行による影響はシミュレーションには反映されてない。

5.2 最適センサ配置と異常検知

(1) 全てのセンサ情報を用いたベイズ損傷検知

FEAから得られた10点（実橋梁のセンサ位置に近い節点）の加速度応答を用い、ベイズ損傷検知を行う。前節で述べた方法を用いて、各損傷シナリオで10試行ずつ作成しBFを算出した。振動数変化とGBFの値の変化を検討するために、それぞれの振動数とGBFの結果を図-11に示す。

図-11のGBFの値は各損傷シナリオ10試行の平均値を用いている。また、グラフの左側の縦軸は振動数を、右側はBFを表している。横軸は、き裂進展の長さを表し、縦の黒点線までが下フランジのき裂（図-11のCrack in lower flange）を、黒点線以降はウェブプレートへのき裂（図-11のCrack in web plate）の長さを表す。

図-11の振動数変化について考察する。曲げ1次振動数に関してはき裂の進展による変化はほとんどみられない。曲げ2次、曲げ3次の振動数に関しては下フランジへのき裂に対して振動数の変化は微弱であるが、ウェブプレートへのき裂進展とともに大きな減少傾向がみられる。INT状態とDMG2状態での振動数を比較すると、損傷によって曲げ2次は1.2%の減少、曲げ3次は3.2%減少している。

図-11のBF変化について考察する。き裂進展に伴ってBF値は上昇傾向にあり、特にウェブプレートへき裂の進展につれBFが大きく上昇している。これは曲げ2次、曲げ3次の振動数減少傾向と相関がみられる。しかしながら、DMG1ではBF値が閾値（赤線）を下回っている。実橋梁のDMG1シナリオでは、BFが閾値を上回




図-12 FEAのセンサ10個配置のときのLBF.





図-13 $N_0 = 3$ の条件での最適センサ配置
(有限要素解析: FEA).

っていたが、FEAは異なる傾向を示している。車両走行による影響がシミュレーションには反映されてないこと、また既往の研究²⁶⁾で報告された温度上昇による境界条件変化の影響については、今回のFEAでは考慮していないため、温度がDMG1の異常検知に何らかの影響を及ぼしている可能性があると考えられる。実際のモニタリングにおいても、短期的な温度変化や支承固着による境界条件の変化などが複雑に影響を及ぼす橋梁であれば、それらを無視して適切に損傷検知を知らせることは容易ではないと考える。ただし、温度変化のような季節変動は周期性があるため、1年間などの長期データを参照データ（reference data）として取得することで、周期性も考慮されたベイズ損傷検知は有効であると考えられる。以上の考察より、GBFではウェブプレートへのき裂進展から損傷度合いの把握が可能であることが分かる。


図-12にFEAのセンサ数10個のときのLBFを示す。GBFと同様にウェブプレートへのき裂進展とともにほとんどのセンサのBFは閾値を上回り、損傷位置に最も近いセンサA1が最も大きな値を示していることが分かる。一方で、センサA10のBFは、下フランジへのき裂進展時から閾値を上回っている。これは、車両走行の出口付近での過渡応答や、実橋梁には存在しない弾性ばね導入の影響と考えられる。

(2) センサ数を減らしたときのベイズ損傷検知

FEAでシミュレートした加速度データにEFI法を適用するにあたって、実橋梁と同じ前提条件を用いる。すなわち、対象とするモードは曲げ1次、曲げ2次、曲げ3次モードの3つで、センサ数 $N_0 = 3$ とする。モード形状



1) GBF



2) LBF

図-14 $N_0 = 3$ の最適センサ配置 (A3, A6, A10) の加速度から求めた BF (損傷位置: 桁端部).

情報は下フランジ全ての節点のモード形状ベクトルを用いる. EFI によるセンサ配置を図-13 に示す. 実橋梁でのセンサ配置 (図-5) とほぼ一致する結果となった.


EFI 法により配置されるセンサの加速度から求めた GBF と LBF をそれぞれ図-14(a)と(b)に示す. 図-14(a)の GBF をみると, センサ数 10 個の配置のときと同様, ウェブプレートへのき裂が進展すると損傷度合いの把握が可能であることが分かる. 図-14(b)の LBF をみると, 実橋梁では損傷位置と反対側の桁に設置したセンサ A6 の LBF が大きな値を示していたが, FEA ではセンサ A3 が最も大きな値を示している. これは, 現場実験においては道路の配置の都合上路面の中央を走行できなかったのに対し, FE モデルでは各 I 桁から等距離を車両が走行し, 車両走行によって橋梁が受ける力が損傷と同じ桁に伝わりやすいことが要因の 1 つと推察する. また, 前述のとおり, 路面凹凸の影響など車両走行による影響がシミュレーションには反映されていないことも要因であると考えられる. 以上の結果より, EFI 法によって求めたセンサ配置においてもベイズ損傷検知の有効性が高いと考えられる.

(3) 桁中央部の損傷におけるベイズ損傷検知


本研究で検討してきたベイズ損傷検知は複数の振動モードを考慮することで, いずれかの振動モードに変化が生じる程度の損傷であれば, どの位置に生じても概ね検

表-3 損傷位置による振動数の変化 (単位: Hz)

損傷位置	損傷シナリオ	曲げ 1 次	曲げ 2 次	曲げ 3 次
桁端	DMG1	3.18	9.62	22.17
	DMG2	3.17	9.50	21.57
支間中央	DMG1	3.16	9.62	22.17
	DMG2	3.07	9.62	21.76



(a) GBF



(b) LBF

図-15 $N_0 = 3$ の最適センサ配置 (A3, A6, A10) の加速度から求めた BF (損傷位置: 支間中央).

知が可能であることに利点がある. その裏付けとして, 支間中央に損傷がある場合におけるベイズ損傷検知について別途検討を行う. 損傷位置は桁中央のセンサ A3 が損傷位置の真横とする. 損傷度合いは実橋の桁端部の損傷で考えた DMG1, DMG2 と同様の損傷を考える.

表-3 に桁端部の損傷のときと桁中央部の損傷のときの各曲げモードの変化を示す. 曲げ 1 次は桁端部の損傷よりも桁中央部の損傷のときの方が大きく減少していることが分かる. また, 支間中央の損傷位置は曲げ 1 次モードの腹の位置であるのに対して, 曲げ 2 次モードの節の位置にあるため, 曲げ 2 次振動数の変化は認められなかった. 一方で, 表-1 の実測では, 損傷により曲げ 2 次振動数が曲げ 3 次より変化が大きい. これは, 温度変化の影響が想定される. すなわち, 温度上昇に伴い桁が橋

軸方向に伸びようとするが、腐食などにより固着した支承には橋軸方向の拘束力が作用する一方で、ピボット支承は橋軸方向へ片持ちばりとして抵抗することが考えられる。このような温度の影響については文献 24, 26) に検討されている。関連文献で、橋軸方向のばねの変化に対する曲げ振動数への影響を検討した結果、曲げ 3 次振動数より曲げ 2 次振動数のほうが橋軸方向のばねの影響を受けやすく、実測時の温度変化による支承の変状の影響であると考えられる。詳細は文献 24, 26) を参照されたい。

最適センサ配置の「A3, A6, A10」のセンサ組み合わせの加速度データを用いて求めた GBF を図-15(a) に示す。桁端部の損傷のときの GBF は、DMG1 で閾値を越えていなかったが (図-14(a) 参照)、桁中央部の損傷のとき大きく閾値を越えている。これは、損傷位置の真横にセンサ A3 を設置していることと曲げ一次振動数が大きく変化していることが原因であると考えられる。図-15(b) に LBF を示す。センサ A3 が最も大きな値を示しており、損傷位置の推定が可能であることが分かる。以上より、EFI 法で求めた最適センサ配置で損傷位置を変化させた場合でもベイズ損傷検知の有効性が示される。

6. 結論

実橋梁の車両走行実験の加速度データを用いて損傷前後における振動数変化の検討とベイズ損傷検知を行った。振動数に関して、対象とした 3 つの曲げモードのうち曲げ 1 次モードでは損傷前後で振動数が上昇するという結果になり、損傷により橋梁の見かけの剛性が低下し、振動数が下がるというものとなっていた。また、他の 2 つの曲げモードでは振動数は下がっていたが、損傷の度合いや損傷位置を推定することは困難であった。そこでベイズ損傷検知を行い、損傷度合いや損傷位置の推定可能性について検討を行った。加えて、ベイズ損傷検知に用いる加速度センサ数の低減方法についても、最適センサ配置手法を用いて検討を行った。以下に本研究で得られた知見をまとめる。

- 実橋実験に用いた加速度センサ全て (10 個) の情報を用いて行ったベイズ損傷検知では損傷度合いの把握や大まかな損傷位置の推定が可能であった。
- 最適センサ配置手法として EFI 法を用いて、曲げ 1 次、曲げ 2 次、曲げ 3 次モードを対象とし、センサ数を 3 とした最適センサ配置を行った。全てのセンサを用いたときと同様の振動数が同定できたが、センサ数が減ることにより、PSD のパワーが弱く、ノイズが強い場合は振動特性の同定精度が悪くなる可能性があることがわかった。
- 上記の条件での最適センサ配置のセンサ情報を用いてベイズ損傷検知の結果、3 個のセンサでもベイズ損傷検知は有効であると考えられる。
- 実橋梁と同じ前提条件を用いて、FEA でシミュレー

トされた加速度データに EFI 法を適用すると、実橋梁とほとんど同様のセンサ配置となった。

- EFI 法で求めた最適センサ配置でベイズ損傷検知を行った結果、損傷度合いの把握と大まかな損傷位置の推定が可能であることが確認できた。
- FEA より、支間中央の損傷をモデル化した場合でも、最適センサ配置のセンサ情報に基づくベイズ損傷検知は有効であると考えられる。

本研究で提案する手法は、まず有限要素モデルを構築して、モード形状を取得する。次に EFI 法に基づくセンサの最適配置を決定し、長期モニタリングを実施する。なお、センサ数はモニタリングの目的や予算規模等に応じて設定することが望ましい。例えば本研究で対象とした橋梁の場合、桁端部および径間中央部の重大な損傷を検知するという観点から、3 つのセンサ数で検証を行っている。橋梁全体系での損傷検知には GBF を算出し、さらにおよその損傷位置の特定には LBF に着目するのがよい。なお検知が可能な損傷は、曲げ剛性の変化や曲げ 1 次振動数に影響の大きい支承部の固着³⁰⁾のように橋梁全体系の何らかの振動特性に影響を及ぼす程度であることが必要である。ただし、損傷種類までは現状特定できないことに留意する。

今後は、上記観点に基づき、最適センサ配置における多様な損傷位置に対する損傷検知可能性について検討を進めていく。

謝辞

本研究の一部は、科学研究補助金 (基盤研究 (B)、課題番号 22H01576) により行われた。ここに記して謝意を示す。

参考文献

- 1) 国土交通省：道路メンテナンス年報，2020。
- 2) 道路橋定期点検要領，国土交通省道路局，2019。
- 3) Farrar, C.R., Baker, W.E., Bell, T.M., Cone, K.M., Darling, T.W., Duffey, T.A., Eklund, A. and Migliori, A.: Dynamics characterization and damage detection in the I-40 Bridge over the Rio Grande, *LANL report: LA-12767-MS*, 1994.
- 4) Doebling, S.W., Farrar, C.R., Prime, M.B. and Shevitz, D.W.: Damage identification and health monitoring of structural and mechanical systems from changes in their vibration characteristics: A Literature Review, *LANL report, LA-13070-MS*, 1996.
- 5) Ko, J.M. and Ni, Y.Q.: Technology developments in structural health monitoring of large-scale bridges, *Engineering Structures*, Vol.27, pp.1715–1725, 2005.
- 6) 吉岡勉，伊藤信，山口宏樹，松本泰尚：鋼トラス橋の斜材振動連成とモード減衰変化を利用した構造健全度評価，*土木学会論文集 A*, Vol.66, No.3,

- pp. 516-534, 2010.
- 7) Magalhaes, F., Cunha, A. and Caetano E.: Vibration based structural health monitoring of an arch bridge: From automated OMA to damage detection, *Mech. Syst. Signal Process.*, Vol. 28, pp. 212-228, 2012.
 - 8) 金哲佑, 北内壮太郎, 杉浦邦征, 川谷充郎, 甲斐正義: 多径間連続鋼トラス橋の交通振動を用いた損傷検知手法, 土木学会論文集 A1, Vol.69, No.3, pp.557-571, 2013.
 - 9) Nair, K.K., Kiremidjian, A.S. and Law, K.H.: Time series-based damage detection and localization algorithm with application to the ASCE benchmark structure, *J. Sound Vib.*, Vol.291, pp.349-368, 2006.
 - 10) 五井良直・金 哲佑: 多変量自己回帰モデルの特性方程式を用いた橋梁の統計的損傷検知, 土木学会論文集 A2, Vol.78, No1, pp.11-22, 2022.
 - 11) Doehler, M., Mevel, L. and Hille, F.: Subspace-based damage detection under changes in the ambient excitation statistics, *Mech. Syst. Signal Process.*, Vol.45, pp.207-224, 2014.
 - 12) Worden, K., Manson, G. and Fieller, N. R. J.: Damage detection using outlier analysis, *J. Sound Vib.*, Vol.229, pp.647-667, 2000.
 - 13) Kammer, D.C.: Sensor placement for on-orbit modal identification and correlation of large space structures, *J. Guid Control Dynam.*, Vol.14, pp. 251-259, 1991.
 - 14) Papadopoulos, M. and Garcia, E.: Sensor placement methodologies for dynamic testing, *AIAA J*, Vol.36, pp. 256-263, 1998.
 - 15) Heo, G., Wang, M.L. and Satpathi, D.: Optimal transducer placement for health monitoring of long span bridge, *Soil Dyn Earthq Eng.*, Vol.16, pp.495-502, 1997.
 - 16) 五井良直, 金哲佑: 橋梁振動の多変量自己回帰モデルのベイズ推定に基づく異常検知, 材料, 日本材料学会, Vol.67, No.2, pp.143 - 150, 2018.
 - 17) 岡林隆敏, 中忠資, 奥松俊博, 郝 捷馨: 多次元 AR モデルを用いた常時微動による橋梁振動特性の推定と推定精度の検討, 土木学会論文集 A, Vol. 64, No. 2, pp. 474-487, 2008.
 - 18) Kass, R. and Raftery, A.: Bayes Factors, *J of the American Statistical Association*, Vol. 90, No.430, pp. 773-795, 1995.
 - 19) Friswell, M.I. and Castro-Triguero, R.: Clustering of sensor locations using the effective independence method, *AIAA J*, Vol.53, No. 5, pp.1388-1390, 2015.
 - 20) Dongsheng Li, Yaoguang Jiang, Hongnan Li: New sensor placement method based on remodeling innovation, *AIAA J*, Vol. 58, No. 4, pp.1-9, 2020.
 - 21) Bishop, C.M.: Pattern recognition and machine learning. New York: Springer, 2006.
 - 22) Dzunic, Z., Chen, J.G., Mobahi, H., Büyüköztürk, O. and Fisher, J.W.: A Bayesian state-space approach for damage detection and classification, *Mech. Syst. Signal Process*, Vol.96, pp. 239-259, 2017.
 - 23) Jeffreys, H.: An invariant form for the prior probability in estimation problems, *Proceedings of the Royal Society of London*, Vol.186, pp. 453-461, 1946.
 - 24) 三増拓也・金 哲佑・五井良直・林 徹: 実鋼桁橋の損傷前後における振動特性に関する考察, 土木学会論文集 A2, Vol.74, No.2, pp.I_513-I_522, 2018.
 - 25) Van Overschee, P. and De Moor, B.: Subspace identification for linear systems, Kluwer Academic Publishers, 1996.
 - 26) 廣岡拓海・林 徹・金哲佑: 局所的損傷と温度変化による鋼桁橋の固有振動数変化に関する考察, 鋼構造工学シンポジウム論文集, Vol.28, pp. 620-628, 2020.
 - 27) DIANA Documentation Version 10.5.
 - 28) McGetrick, P.J., Kim, C.W., Gonzalez, A. and O'Brien, E.J.: Experimental validation of a drive-by identification method for bridge monitoring, *Str Health Mon*, Vol.14, pp.317-331, 2015.
 - 29) 大竹省吾, 中村一史, 長船寿一, 岩吹啓史, 鳥部智之, 平栗昌明: 道路橋の交通振動の疑似応答解析を用いた応答加速度の推定方法に関する研究, 土木学会論文集 A2, Vol.72, No.2, pp.I_707-I_718, 2016.
 - 30) 金哲佑: 橋梁点検と構造ヘルスマニタリング, 連載企画: 次世代モニタリング技術第 3 回, 橋梁と基礎, Vol.54, pp.46-51, 2020.

(2022 年 9 月 20 日受付)

(2023 年 2 月 10 日受理)