

**2026年5月16日(土)**

企画セッション | 企画セッション (応用数理・AIの活用～デジタルツインから量子計算まで～)

15:00 ~ 16:15 | B会場(環境棟: 3階講義室)

**応用数理・AIの活用 (1)**

座長:宮本 崇(東京科学大学)

15:00 ~ 15:15

[12011] JIS規格とスキャンデータに基づく3次元異形鉄筋モデルの自動生成 (シンポジウム講演概要)

\*車谷 麻緒<sup>1</sup>、松岡 朋輝<sup>1</sup>、黄 璽<sup>2</sup>、相馬 悠人<sup>3</sup> (1. 茨城大学、2. 木更津高専、3. 福島高専)

15:15 ~ 15:30

[12012] 粗骨材と鉄筋の実形状を考慮した鉄筋コンクリートはりの3次元メゾスケール数値実験 (シンポジウム講演概要)

\*新田 祐太郎<sup>1</sup>、伊藤 成央<sup>1</sup>、黄 璽<sup>2</sup>、車谷 麻緒<sup>1</sup> (1. 茨城大学、2. 木更津高専)

15:30 ~ 15:45

[12013] テンプレートモデルを用いた鋼橋点群の構造部材インスタンスセグメンテーション (シンポジウム講演概要)

\*中溝 智也<sup>1</sup>、西尾 真由子<sup>1</sup> (1. 筑波大学)

15:45 ~ 16:00

[12014] 深層学習による橋梁点群からの部材接続グラフ推定 (シンポジウム講演概要)

\*保坂 拓夢<sup>1</sup>、西尾 真由子<sup>1</sup> (1. 筑波大学)

16:00 ~ 16:15

[12015] パラメトリックモデルに基づく点群からの3次元モデル構築における未想定構造に対する不確実性評価手法 (シンポジウム講演概要)

\*石川 大智<sup>1</sup>、本田 利器<sup>1</sup>、全 邦釘<sup>1</sup> (1. 東京大学)

企画セッション | 企画セッション (応用数理・AIの活用～デジタルツインから量子計算まで～)

16:25 ~ 17:25 | B会場(環境棟: 3階講義室)

**応用数理・AIの活用 (2)**

座長:北原 優(北海道大学)

16:25 ~ 16:40

[12016] インフラデジタルツインのためのMCPIによるデータ連携・ツール共有・知識共有化 (シンポジウム講演概要)

\*本田 利器<sup>1</sup> (1. 東京大学)

16:40 ~ 16:55

[12017] マルチスケール大気モデル (MSSG) による微気象解析のための入力データの自動構築 (シンポジウム講演概要)

\*本田 和也<sup>1</sup>、中瀬 仁<sup>1</sup>、松田 景吾<sup>2</sup>、杉山 徹<sup>2</sup>、栗原 祐也<sup>3</sup>、亀田 敏弘<sup>3</sup>、清野 友規<sup>4</sup> (1. 東電設計株式会社、2. 海洋研究開発機構、3. 筑波大学、4. 横浜国立大学)

16:55 ~ 17:10

[12018] 都市規模の地震被害評価のための最適センサー配置と逐次ベイズ更新 (シンポジウム講演概要)

\*湯 東暘<sup>1</sup>、Sukulthanasorn Naruethep<sup>1</sup>、野村 怜佳<sup>1</sup>、郭 佳<sup>2</sup>、大野 晋<sup>1</sup>、野島 和也<sup>3</sup>、森 篤史<sup>3</sup>、佐藤 誠一<sup>3</sup>、櫻庭 雅明<sup>3</sup>、寺田 賢二郎、森口 周二 (1. 東北大学、2. 京都大学、3. 日本工営株式会社)

17:10 ~ 17:25

[12019] 不均一分散変分オートエンコーダに基づく静的データ融合のための生成フレームワーク (シンポジウム講演概要)

\*ダルマシリ ミゲルアラチラゲカスンマドゥサンカ<sup>1</sup>、本田 利器<sup>1</sup> (1. 東京大学)

企画セッション | 企画セッション (応用数理・AIの活用～デジタルツインから量子計算まで～)

2026年5月16日(土) 15:00～16:15 | B会場(環境棟：3階講義室)

### 応用数理・AIの活用 (1)

座長:宮本 崇(東京科学大学)

15:00～15:15

[12011] JIS規格とスキャンデータに基づく3次元異形鉄筋モデルの自動生成 (シンポジウム講演概要)

\*車谷 麻緒<sup>1</sup>、松岡 朋輝<sup>1</sup>、黄 璽<sup>2</sup>、相馬 悠人<sup>3</sup> (1. 茨城大学、2. 木更津高専、3. 福島高専)

15:15～15:30

[12012] 粗骨材と鉄筋の実形状を考慮した鉄筋コンクリートはりの3次元メソスケール数値実験 (シンポジウム講演概要)

\*新田 祐太郎<sup>1</sup>、伊藤 成央<sup>1</sup>、黄 璽<sup>2</sup>、車谷 麻緒<sup>1</sup> (1. 茨城大学、2. 木更津高専)

15:30～15:45

[12013] テンプレートモデルを用いた鋼橋点群の構造部材インスタンスセグメンテーション (シンポジウム講演概要)

\*中溝 智也<sup>1</sup>、西尾 真由子<sup>1</sup> (1. 筑波大学)

15:45～16:00

[12014] 深層学習による橋梁点群からの部材接続グラフ推定 (シンポジウム講演概要)

\*保坂 拓夢<sup>1</sup>、西尾 真由子<sup>1</sup> (1. 筑波大学)

16:00～16:15

[12015] パラメトリックモデルに基づく点群からの3次元モデル構築における未想定構造に対する不確実性評価手法 (シンポジウム講演概要)

\*石川 大智<sup>1</sup>、本田 利器<sup>1</sup>、全 邦釘<sup>1</sup> (1. 東京大学)

# JIS 規格とスキャンデータに基づく 3 次元異形鉄筋モデルの自動生成 (シンポジウム講演概要)

Automated three-dimensional modeling of deformed steel bars  
incorporating JIS standards and scan data  
(Proceedings of Symposium on Applied Mechanics)

車谷 麻緒 (茨城大) 松岡 朋輝 (茨城大) 黄 璽 (木更津高専) 相馬 悠人 (福島高専)

Mao KURUMATANI, Ibaraki University

Tomoki MATSUOKA, Ibaraki University

Xi HUANG, Kisarazu KOSEN

Yuto SOMA, Fukushima KOSEN

E-mail: mao.kurumatani.jp@vc.ibaraki.ac.jp

This study proposes a simple and fully automated method for generating three-dimensional models of deformed steel bars. The method focuses on the rib geometry, which has a significant influence on bond performance, and parametrically reproduces its shape using a mathematical model based on exponential functions. In addition, dimensional requirements specified in the JIS (Japanese Industrial Standards) standard are incorporated, while geometrical features undefined by the JIS specifications are enhanced by referencing 3D-scanned data of actual reinforcing bars. The proposed method automatically constructs surface meshes during the modeling process, enabling immediate output in the widely used STL format.

## 1. はじめに

鉄筋コンクリート (RC) 構造物は, 社会インフラを支える構造形式として広く用いられている. RC 構造物が本来の力学性能を発揮するためには, コンクリートと鉄筋が一体的に挙動することが求められ, 特に両者の界面で生じる付着特性が構造性能を支配する重要な因子となる. なかでも, 異形鉄筋の表面に設けられた節 (ふし) 形状は, コンクリートとの機械的な噛み合いを通じて付着挙動を決定づける主要な要素であり, 部材の変形性能や破壊性状に直接的な影響を及ぼすことが知られている<sup>1)</sup>.

近年の計算機性能の飛躍的な向上により, 異形鉄筋の節形状を考慮した大規模な非線形解析を実行できる環境が整い, 数値解析そのものは技術的に十分可能となりつつある. しかし, 数値解析に先立つモデル構築 (プリプロセス) において, 節形状まで考慮した 3 次元モデルの作成は, 依然として膨大な作業負荷をとともなう. 複雑な幾何形状を有する異形鉄筋を, 多様な配筋条件に応じて個別にモデリングする過程は手作業に依存する部分が多く, その時間的・労力的なコストが詳細な数値解析を広く普及させる上での大きな障壁となっている.

こうした背景から, 工業規格が定める幾何学的制約を満足しつつ, 実物形状の特徴を反映した異形鉄筋の 3 次元モデルを, 簡便かつ高精度に自動生成する手法の確立が求められている. そこで本研究では, 異形鉄筋の 3 次元モデルを簡便かつ自動的に生成する手法を提案する. まず, 付着性能に大きな影響を与える節形状について, 指数関数に基づく数式モデルを用いてパラメトリックに再現する. さらに, JIS 規格<sup>2)</sup> が定める寸法条件を組み込むとともに, JIS 規格で定められていない部分の形状については, 実物鉄筋の 3D スキャンデータを参照することで, 幾何学的特徴の再現性を向上させる. また, 提案手法は形状モデルの構築と同時に表面メッシュの自動生成も可能である. 数値解析例を通して, 複雑な配筋条件を有する実際の鉄筋コンクリート部材であっても, 短時間で高精度に 3 次元モデルおよび表面メッシュの生成が可能であることを示す.




Fig.1 3D modeling of deformed steel bar




Fig. 2 3D models of longitudinal and shear reinforcements generated by the proposed method

## 2. 異形鉄筋モデルの自動生成手法

本研究では、異形鉄筋の3次元モデルを自動生成する手法を提案する。提案手法の特徴は以下のとおりである。

- 数式モデルを用いて、節形状の輪郭をパラメトリックに表現する。
- JIS規格に定められた寸法条件を満足させる。
- JIS規格に定められていない部分については、実物の異形鉄筋の3Dスキャンデータを参照し、実形状の特徴を反映させる。
- 3次元形状の構築と同時に、表面メッシュも自動生成する。

Fig. 1 に示すように、次式の指数関数  $f(x)$  を用いて、異形鉄筋の節の輪郭線を表現する。

$$y = f(x) + D = Ae^{-Bx^2} + D \quad (1)$$

ここで、パラメータ  $A \sim E$  は、異形鉄筋の種類（節形状）に応じて定まる量であり、それぞれの図的解釈は Fig. 1 に示すとおりである。

JIS規格で定められている形状要件を満足するように、パラメータ  $A \sim E$  を決定する。具体的には、JIS規格において、公称直径、節の平均間隔の最大値、節の高さの最小値と最大値が定められており、これらを満足するようにパラメータ  $A, C, D, E$  を決定する。

異形棒鋼のJIS規格では、節の高さや間隔に関する要件は規定されている一方、節の細部形状については明確な規定がない。JIS規格で定められていない部分の形状については、実物の異形鉄筋の3Dスキャンデータを用いて、節の細部形状を再現する。具体的には、Fig. 1 に示すように、3Dスキャンデータの輪郭線と提案手法による再現形状を対照させることで、パラメータ  $B$  を決定する。

異形鉄筋を軸方向に周期的な軸対称構造とみなせば、円筒座標系を利用して、Fig. 1 の  $y$  を半径成分として与えることで、異形鉄筋の3次元形状および表面メッシュを容易に自動生成することができる。

## 3. 数値解析例

実際の鉄筋コンクリート部材を対象に、提案手法を用いて鉄筋の配置と形状を3次元で再現した。部材の断面寸法 (mm) は  $600 \times 800$ 、全長 (mm) は 2100 である。配筋は、D25 の軸方向鉄筋 16 本と D10 のせん断補強筋 20 本で構成される。

提案手法により、軸方向鉄筋 16 本およびせん断補強筋 20 本の3次元モデルと表面メッシュを自動生成した。生成した表面メッシュを STL 形式で出力し、可視化した結果を Fig. 2 に示す。この結果から、多数の鉄筋が存在する複雑な配筋であっても、3次元モデルと表面メッシュを一貫して自動生成できることが確認できる。これにより、配筋情報から自動生成までの一連のワークフローに対し、提案手法が高い実用性と拡張性を有することが示された。

## 4. おわりに

本論文では、鉄筋コンクリートの付着性能に大きな影響を与える節形状に着目し、異形鉄筋の3次元モデルおよび表面メッシュを簡便かつ自動で生成する手法を提案した。

## 参考文献

- 1) Goto, Y.: Cracks formed in concrete around deformed tension bars, *ACI Journal*, Vol. 68, pp. 244-251, 1971.
- 2) コンクリート標準示方書（規準編）JIS規格集，土木学会，2023.

# 粗骨材と鉄筋の実形状を考慮した鉄筋コンクリートはりの3次元メゾスケール数値実験 (シンポジウム講演概要)

## Three-Dimensional Meso-Scale Numerical Simulation of Reinforced Concrete Beams Incorporating Realistic Aggregates and Reinforcement (Proceedings of Symposium on Applied Mechanics)

新田 祐太郎 (茨城大) 伊藤 成央 (茨城大) 黄 璽 (木更津高専) 車谷 麻緒 (茨城大)

Yutaro NITTA, Ibaraki University

Nao ITO, Ibaraki University

Xi HUANG, Kisarazu KOSEN

Mao KURUMATANI, Ibaraki University

E-mail: mao.kurumatani.jp@vc.ibaraki.ac.jp

This study presents a numerical method for simulating the three-dimensional meso-scale fracture behavior of reinforced concrete (RC) by incorporating the realistic geometries of coarse aggregates and deformed reinforcing bars. The geometry of coarse aggregates was captured using a 3D scanner and directly integrated into the numerical model, while the three-dimensional shape of the ribs on deformed bars was explicitly modeled in the finite element mesh. The crack propagation behavior in mortar was simulated using a damage model based on the modified von Mises criterion. Comparisons between numerical results and experimental observations demonstrated good agreement in terms of load-displacement response and crack growth, confirming that the proposed method can quantitatively reproduce the fracture process of RC beams.

### 1. はじめに

数値実験とは、実施が比較的難しい実験を現実で試す代わりにコンピューターの中で再現・解析する手法のことを指す。特に、鉄筋コンクリート等の破壊挙動をコンピューター上の数値解析で再現して評価する手法は、近年、活発に研究されている。現実の実験では、多大なコストと時間を要し、実験装置や供試体寸法に起因する制約も大きい一方、数値実験では、現実の実験では困難な条件設定を比較的容易に行うことができ、実施の負担も小さい。さらに、直接把握が困難な数値などを算出できる点においても、破壊挙動の検討に非常に有用である。

既往研究では、粗骨材の3次元形状や粒度分布を考慮した解析手法<sup>1)</sup>が提案されており、粗骨材を無作為に充填し、コンクリートの非均質性を高い精度で再現している。しかし、粗骨材の形状や分布の違いは、ひび割れの発生位置や損傷挙動に影響を及ぼすため、解析精度の向上には、より実物に近い形状を考慮することが重要である。

実験で観察される現象を数値解析上で忠実に再現するには、不規則なひび割れ挙動に加え、粗骨材や鉄筋の形状・分布を高い精度でモデル化する必要がある。本研究では、実物に近い鉄筋コンクリートの3次元モデルを構築し、数値解析を行うことで、ひび割れの進展過程を忠実に可視化し、変形の程度を視覚的に把握する。

### 2. 数値解析手法

#### 2.1 粗骨材の形状と分布を反映したコンクリートのメゾスケールモデリング

粗骨材の複雑な形状を再現するため、実物の粗骨材 100 個を 3D スキャナでスキャンし、データを 100 個生成する。得られたデータに対して、拡大・縮小・回転の操作を行い、データ数を増加させる。本研究では、車谷らが考案した粗骨材の充填アルゴリズム<sup>2)</sup>を用いる。粗骨材を鉄筋・粗骨材同士が重複しないように目標とする充填率に達するまで 3 次元空間内に無作為に選択・配置することで、実際のコンクリートに近いメゾスケールモデルを生成することが可能である。




図-1 曲げ破壊型 RC はりの寸法、支持・載荷条件

#### 2.2 コンクリート・鉄筋の材料モデル

コンクリートの材料モデルには、車谷らが考案した損傷モデル<sup>3)</sup>を適用する。損傷モデルの構成則は次式で表される。

$$\sigma = (1 - D)c : \varepsilon \quad (1)$$

ここで、 $\sigma$  はコーシー応力テンソル、 $D$  は損傷変数、 $c$  は弾性係数テンソル、 $\varepsilon$  は微小ひずみテンソルである。

本研究では、コンクリートをモルタルと粗骨材の二相材料とする。各要素の体積のうちモルタルの体積率を  $V$  とする。粗骨材は損傷しないものとして、モルタルの損傷のみを考えると、損傷変数  $D(\varepsilon_e)$  は次式となる。

$$D(\varepsilon_e) = 1 - \frac{\varepsilon_0 \alpha_0}{\varepsilon_e} \exp \left\{ - \frac{E \varepsilon_0 \alpha_0}{G_f} h_e (1 - V) \left( \frac{\varepsilon_e}{\alpha_D} - \varepsilon_0 \right) \right\} \quad (2)$$

$\varepsilon_0$  はモルタルの破壊発生ひずみ、 $h_e$  は要素長さ、 $G_f$  はモルタルの破壊エネルギーである。また、 $\alpha_0$  と  $\alpha_D$  はそれぞれ次式の関係を示す値である。

$$E_m = \alpha_0 E, \quad \varepsilon_m = \alpha_D^{-1} \varepsilon \quad (3)$$

$E_m$  はモルタルのヤング率、 $\varepsilon_m$  は要素内のモルタルの等価ひずみ、 $\varepsilon$  は要素全体の等価ひずみである。本研究では、修正 von-Mises 基準に基づく等価ひずみを用いる。

鉄筋の材料モデルには、非線形等方硬化則に基づく von-Mises 塑性モデルを適用した。降伏関数  $f$  は次式で表される。

$$f = \sigma_v - \sigma_y - Q(1 - e^{-bp}) \quad (4)$$

$\sigma_v$  は von-Mises 相当応力、 $\sigma_y$  は初期降伏応力、 $p$  は相当塑性ひずみ、 $Q$  および  $b$  は鉄筋の非線形硬化パラメータである。




図-2 荷重-変位関係




図-3 RC はりの実験結果と解析結果の比較




図-4 コンター図と不連続変形を統合させたひび割れ進展挙動の可視化結果

### 3. 鉄筋コンクリートはりの数値実験とその可視化

#### 3.1 実験概要および数値解析条件

本研究では、過去に実験をして、結果が出ている研究<sup>4)</sup>を対象とされたRCはりを参考に、モデルを作成して数値シミュレーションを実施したのち、可視化を行った。図-1は、寸法、支持・载荷条件を含んだ曲げ破壊型RCはりのモデルである。

有限要素モデルには四面体1次要素を使用し、载荷点には10mmの強制変位を与える条件で解析を実施し、粒度分布は規格内に収まるよう作成した。モルタルの材料パラメータはヤング率を13 GPa、ポアソン比を0.2、圧縮引張強度比を15、破壊エネルギーを0.1 N/mm、破壊発生ひずみを0.0002とする。粗骨材の材料パラメータはヤング率を60 GPa、ポアソン比を0.2とした。鉄筋のパラメータはヤング率を190 GPa、ポアソン比を0.3、降伏応力を380 MPa、非線形硬化パラメータ $Q, b$ をそれぞれ100 MPa、10とする。また、解析結果と実験結果<sup>4)</sup>の荷重-変位関係を図-2に示す。解析結果から、曲げ破壊の特徴である延性的な挙動を適切に捉え、実験結果との良好な一致が確認できる。

#### 3.2 ひび割れの可視化結果

本研究では、損傷を解析し、四面体要素をボロノイ状に分割して不連続変形に変換することでひび割れを可視化している。はじめに、実験結果(写真とトレース)と数値実験による解析結果を比較したものを図-3に示す。不連続変形のひび割れが複雑に進展していることが確認でき、実験と解析でほぼ合っていることが分かる。また、有限要素法の解析で得られた最大主ひずみに基づくコンター図を独自に作成し、連続的な色調変化を用いることで、部材の変形

度合いを直感的に把握できるようにした。内部の様子を見やすくするために、一部の粗骨材を透明にして可視化したモデルを図-4に示す。ひび割れが粗骨材を回避して進展し、複雑で現実的な破壊挙動を再現できている。

#### 4. おわりに

実物に近い形状の粗骨材や鉄筋を有する鉄筋コンクリートモデルを構築し、粗骨材の分布を考慮した損傷モデルを用いて数値解析を行った。その結果、高精度な可視化を可能にし、鉄筋コンクリートはりの破壊特性を捉えた複雑なひび割れ挙動を再現した。また、不連続変形のひび割れとコンター図を重ね合わせることで、変形の程度を直感的に把握できることを示した。

#### 参考文献

- 1) 那須川佳祐, 升井尋斗, 車谷麻緒: 粗骨材の形状と粒度を再現した鉄筋コンクリートはりの3次元メゾスケール破壊シミュレーション, 土木学会論文集, Vol. 79, No.11, pp. 2300190, 2023.
- 2) 車谷麻緒, 中嶋貴将, 洪澤駿斗, 中畑和之: 粗骨材の実形状を再現したコンクリートの3次元メゾスケールモデリング, 土木学会論文集, Vol. 82, No. 15, 25-15015, 2026.
- 3) 車谷麻緒, 加藤匠, 佐々木浩武: 非均質性を考慮した損傷モデルの定式化とその性能検証, 土木学会論文集A2(応用力学), Vol.75, No.1, 47-54, 2019.
- 4) 羽生隼輝, 車谷麻緒: 数値解析のV&Vに向けた曲げ破壊型鉄筋コンクリートはりのValidation実験, 土木学会論文集, Vol.80, No.15, 23-15016, 2024.

# テンプレートモデルを用いた鋼橋点群の構造部材インスタンスセグメンテーション (シンポジウム講演概要)

## Template-based structural member instance segmentation for steel bridge point cloud data (Proceedings of Symposium on Applied Mechanics)

中溝 智也 (筑波大院・システム情報工学研究群) 西尾 真由子 (筑波大・システム情報系)  
Tomoya NAKAMIZO, University of Tsukuba  
Mayuko NISHIO, University of Tsukuba  
E-mail: nakamizo.tomoya.tkb\_gx@u.tsukuba.ac.jp

This study proposes an instance segmentation method for structural members of steel girder bridges toward finite element (FE) model reconstruction. The method employs a parametric bridge template model representing the basic structure and consists of two stages: main and secondary member recognition. Geometric parameters are estimated using kernel density estimation to generate an initial model. Main members are identified using normal-direction classification and template-based clustering, and their geometric parameters are estimated. Secondary members are extracted using spatial constraints derived from the template model and geometric pattern grouping. Validation with synthetic bridge datasets shows high segmentation accuracy for major members, with geometric errors within several tens of millimeters. These results demonstrate the effectiveness of a template-guided, structure-aware framework for reconstructing bridge FE models from point cloud data.

### 1. はじめに

近年、橋梁の維持管理の効率化・高度化に向け、点群データの利活用が進められている。著者らはこれまで、点群から既存橋梁の有限要素 (FE) モデルを構築する手法について研究しており、部材レベルでの検証を行ってきた<sup>1)</sup>。研究対象とする鋼橋は、コンクリート橋と比較して複雑な部材構成である。部材レベルでのモデル化を実現するには、座標や色情報のみを持つ点群がどの部材に属するかを判定するインスタンスセグメンテーションが必要となる。しかし、部材数の多さや点群計測におけるノイズ・データ欠損により、各部材を認識する手法は確立されていない。

そこで本研究では、鋼橋を構成する部材の幾何学的パターンに着目し、橋梁テンプレートモデルを用いた点群からの FE モデル構築手法の確立を目的とする。本報告では鈹桁橋を対象に、主部材分類と幾何モデル生成、ならびに副部材のインスタンスセグメンテーション手法を示す。

### 2. テンプレートモデルの定義と概要

桁橋の上部構造は、車両などが通る床版を主桁が支える構造をしている。これらの部材は構造の大部分を占めており、またどの橋梁にも共通して存在する主部材といえる。また、橋梁が満たすべき性能によって構成が異なっている横桁や対傾構などの部材は副部材と定義される。

本研究で提案する橋梁テンプレートモデルは、主部材である床版と主桁 (I 桁) で構成し、各部材の寸法と位置をパラメータとして有したシェルモデルとした。橋軸方向を  $x$ 、橋軸直角方向を  $y$ 、鉛直方向を  $z$  軸と定義し、主部材の空間的な配置パターンを基に各テンプレートを配置する。また、I 桁テンプレートモデルは上下フランジ、ウェブで構成され、補剛材が任意に追加される仕様とした。このように、本研究では主部材をテンプレートモデルとして定義し、対象点群に合わせて初期テンプレートモデルを生成する。

### 3. 提案手法

本手法は、構成要素の幾何学的なパターンに着目した、主部材認識と副部材認識の 2 ステップで構成される。テンプレートモデルを基に部材認識を実施し、分類した各部材点群から幾何構造を推定することでモデルを構築する。

橋梁点群から構造の概形を把握するため、座標系の正規化と構造寸法推定を行った。まず点群の前処理として FPS (Farthest Point Sampling) によるダウンサンプリング、点群法線ベクトル計算を実施した。次に、橋梁の主軸を推定しテンプレートモデルと座標系を整合させるため、主成分分析を適用した。第一主成分を橋軸方向、第二主成分を橋軸直角方向、第三主成分を鉛直方向と定義した。さらに、各軸方向に対してカーネル密度推定 (KDE) を適用し、密度分布の形状から主桁の本数、位置および寸法を自動推定した。射影座標  $x_i$  に対する密度関数は以下の式で与えられる。

$$\hat{f}(x) = \frac{1}{nh} \sum_{i=1}^n \exp\left(-\frac{(x-x_i)^2}{2h^2}\right) \quad (1)$$

ここで  $n$  は点数、 $h$  はバンド幅である。橋梁点群を各座標軸方向へ射影すると、部材位置に対応して点が集中するため、密度関数の局所最大値を抽出した。閾値は、密度分布の低変動領域における平均値の 1.1 倍を相対閾値として設定した。さらに、密度関数が閾値以上となる区間を抽出した。 $y$  座標値 KDE から主桁の  $y$  位置および桁幅を算出し、 $z$  軸座標値 KDE から床版位置、桁位置および桁高を求めた。なお、床版の長さおよび幅は点群全体の最大・最小座標値から算出した。以上より、推定された構造寸法をもとに初期のテンプレートモデルを生成した。




Fig. 1 Point clouds and KDE-based dimension estimation.




Fig. 2 Structural member instance segmentation results (left) and constructed main-member template model (right).

次に、主部材の点群を識別するため、テンプレートモデルを基準とした主部材抽出処理を実施した。鋼構造物は直交的構成を有するため、部材主要面の法線方向は部材分類に有用である。特に、床版と主桁のフランジ面は $z$ 方向、主桁のウェブ面は $y$ 方向を向いている。そこで、各点の法線ベクトルの絶対値最大成分に基づき $x, y, z$ 方向面に分類した。次に、テンプレートモデルの各面との法線方向と距離に基づいて、点群をクラスタリングした。距離閾値は、実橋梁寸法を参考に試行錯誤の結果  $200 \text{ mm}$  と設定し、どの面にも属さない点は後述する副部材認識での候補点とした。

そして、分類した各クラスターの幾何構造を推定することでテンプレートモデルの幾何構造を更新した。具体的には、各クラスターの重心計算、および端部推定を実施した。端部推定には、ノイズ除去でよく用いられる統計的外れ値除去を適用し、ノイズの影響を低減したうえで部材の幾何寸法をロバストに推定した。以上より、算出した構造寸法をもとにテンプレートモデルを更新し、主桁および床版の幾何モデルを生成した。これにより、橋梁上部構造の基本的な部材配置および主要寸法を点群データから自動的に取得することが可能となる。

最後に、主部材の空間配置を利用して副部材の認識を行った。本検証で対象とした副部材は横桁および垂直補剛材である。本研究では、副部材が床版下かつ主桁間の限定された領域に配置され、さらに部材同士が直交するという構造的特性に基づき、テンプレートモデルを基準として探索空間を区間分割した。具体的には、主桁ウェブ、フランジで囲まれた補剛材領域および主桁間領域を定義した。各区間内において、法線方向分類により $x$ 方向面をウェブおよび補剛材候補、 $z$ 方向面をフランジ候補とした。その後、各領域内で DBSCAN (Density-Based Spatial Clustering of Applications with Noise) を用いて平板単位までクラスタリングを行った。主桁領域で得られたクラスターを補剛材として抽出した。横桁については、平板クラスター間の幾何関係に基づき、直交関係および上下配置関係を満たす3面集合を同定することで横桁インスタンスを構成した。具体的には、直交関係を満たす重心位置が近い3つの面をグループ化した。以上のように、空間的制約と部材の幾何パターンを明示的に利用することで、副部材の検出を可能にした。

#### 4. 合成点群データを用いた検証

標準的な6主桁鉸桁橋 (Bridge A) と5主桁鉸桁橋 (Bridge B) の3Dモデルを作成し、メッシュ上に点群を生成したデータを用いた。3Dモデルは Autodesk Fusion<sup>2)</sup>を用いて作成し、著者らの先行研究<sup>1)</sup>で調査した実橋梁点群のノイズレベル、密度分布を用いて、それぞれ100万点サンプリングした。また、各点に部材インスタンスラベルを付与した正解データを作成し、提案手法により分類した点群のラベル

Table 1 Instance-level IoU for each structural member (standard deviation).

|               |        | Bridge A                          | Bridge B                          |
|---------------|--------|-----------------------------------|-----------------------------------|
| Deck          |        | 0.85                              | 0.93                              |
| Main girders  | Web    | 0.97<br>( $3.8 \times 10^{-3}$ )  | 0.96<br>( $8.8 \times 10^{-3}$ )  |
|               | Flange | 0.97<br>( $3.3 \times 10^{-3}$ )  | 0.91<br>( $5.0 \times 10^{-3}$ )  |
| Cross girders |        | 0.91<br>( $18.8 \times 10^{-3}$ ) | 0.95<br>( $10.4 \times 10^{-3}$ ) |
| Stiffeners    |        | 0.55<br>( $86.9 \times 10^{-3}$ ) | -                                 |

と比較した。評価指標には、各点の予測ラベルと正解ラベルの一致に基づく IoU (Intersection over Union) を用いた。

セグメンテーション結果を Fig. 2 に示す。両データともに主要な部材が検出できたことが確認された。一方、主桁の上フランジは床版に接していたことから、床版として誤分類されていた。どのインスタンスにも属さない未分類の点群は、主に床版や桁の板厚部分に多く見られた。これは板厚部など主要面に属さない点群に対応している。各部材の IoU を Table 1 に示す。床版以外の複数存在する部材については部材種別ごとの平均 IoU と標準偏差を示す。床版、主桁、横桁は両データともに高精度で分類できており、インスタンスごとの分類精度のばらつきも小さかった。一方、Bridge B にのみ存在する補剛材については、相対的に低い結果となった。各インスタンスの点数が平均150点程度で相対的に少なく、横桁との近接により誤吸収される傾向が確認された。また、推定した幾何構造においては、位置および寸法の誤差は概ね数 mm ～ 十数 mm 程度であり、橋梁スケールに対して十分小さい誤差であることを確認した。

#### 5. 結論

本研究では、鋼橋点群データから FE モデル構築を目的とした構造部材インスタンスセグメンテーション手法を提案した。橋梁テンプレートモデルを基準とし、法線方向に基づく分類により主部材を同定するとともに、推定された寸法に基づき主部材の幾何モデルを生成した。さらに、主部材に基づく空間制約と部材の幾何パターンを利用することで、副部材のインスタンスセグメンテーションを実現した。合成点群を用いた検証の結果、主桁および横桁については高精度な認識が可能であることを確認した。本研究は、橋梁構造の知識を明示的に利用することで点群から構造部材を自動モデリングする枠組みを示したものである。今後は、部材接合関係の同定に基づく副部材モデル化を行うとともに、構築した FE モデルの妥当性検証を進める。

#### 謝辞

本研究は JST 創発的研究支援事業 JPMJFR205T 及び、JST 次世代研究者挑戦的研究プログラム JPMJSP2124 の支援を受けたものです。

#### 参考文献

- 1) T. Nakamizo and M. Nishio: Shell Model Reconstruction of Thin-Walled Structures from Point Clouds for Finite Element Modelling of Existing Steel Bridges, Sensors, 25 (13), 4167, 2025.
- 2) Autodesk Inc.: Autodesk Fusion, software, <https://www.autodesk.com/jp/education/edu-software/fusion>, Accessed March 3, 2026.

# 深層学習による橋梁点群からの部材接続グラフ推定（シンポジウム講演概要） Deep learning-based estimation of structural component connectivity graph from bridge point clouds (Proceedings of Symposium on Applied Mechanics)

保坂 拓夢（筑波大院・システム情報工学研究群） 西尾 真由子（筑波大・システム情報系）  
 Takumu HOSAKA, University of Tsukuba  
 Mayuko NISHIO, University of Tsukuba  
 E-mail: s2210657@u.tsukuba.ac.jp

This study develops a prediction method of structural topology graph from bridge point cloud data for uses in efficient maintenance and digital twinning. The method consists of the processes of component-level segmentation, clustering to extract instances, and prediction of infer connectivity between instance pairs to form component connectivity graphs. The method was evaluated on the SemanticBridge dataset, an opened dataset of bridge point clouds. Experiments show major components are segmented accurately, whereas bearing remains difficult. Bearing-related instance noise degrades graph quality, highlighting the need to handle small but critical components. Training connectivity estimation in the predicted-instance space (Pred train) improves robustness against instance extraction errors and suppresses false-positive edges. The proposed method enables reliable connectivity prediction for bridges where bearings are appropriately recognized.

## 1. 序論

近年国内では、特に高度経済成長期に整備された橋梁を中心にインフラ構造物の老朽化対策が課題となっている。現在の定期点検体制では近接目視が求められるが、人員と予算の制約が大きく、特に技術者不足が深刻な地方自治体では継続的な実施が難しい。一方、レーザー計測等で得られる点群データは、構造物を非接触かつ高密度に3次元計測でき、構造状態に関する情報が得られる手法として注目されている。しかし、点群自体は単なる点の集合であり、床版・桁・橋脚・橋台・支承といった多数の機能の異なる部材で構成される橋梁では、部材区分や部材間の接続関係といった情報がなければ上手く活用できない。そのため、構造全体の点群を取得しても維持管理に必要なデータとするには多くの手作業が必要となる。点群をBIM/CIMやデジタルツインの運用に活かすには、点群から構造情報の明示的な表現を効率的に獲得することが重要となっている。

そこで本研究では、構造全体の点群から部材識別して部材接続関係推定を行い、「部材接続グラフ」として可視化する深層学習手法を構築し、橋梁の点群データを対象として、その精度と妥当性を検証する。

## 2. 提案手法

Fig. 1 に本手法の部材接続関係推定のプロセスを示す。入力は橋梁の点群データ、出力はノードが部材インスタンス、エッジが部材間接続を表す部材接続グラフである。本手法は「部材抽出モデル」と「接続関係推定モデル」の2つの深層学習モデルで構成した。まず点数・密度のばらつきに対処するため、点群を橋軸方向に一定の長さで50%の重なりを設けながらブロック分割し、ダウンサンプリングで点数を揃える。次にこの前処理を施した各ブロックの点群を入力として、PointNet++による「部材抽出モデル」でセマンティックセグメンテーションで各点を床版・桁・橋脚・橋台・支承の5クラスに分類し、点群座標に基づいて橋梁全体へ統合する。そして、同一クラス内でのクラスタリングでインスタンス化を行い、例えば「橋脚1」「橋脚2」というように、部材インスタンスを抽出する。

「接続関係推定モデル」は Fig.1 中に示すように、PointNet<sup>2</sup>で抽出した各部材インスタンスの形状特徴を点群から集約し、多層パーセプトロン(MLP)で接続確率を推定する。そして部材インスタンス間の接続確率を隣接行列Adjacency Matrix で表し、閾値で接続・非接続かを決定する。深層学習モデルの学習では、損失関数と最適化手法にそれぞれ、「部材抽出モデル」で多クラス分類の交差エントロピーとAdamW、「接続関係推定モデル」で二値交差エン




Fig.1 Deep learning based pipeline for bridge component connectivity graph generation



Fig.2 Test data of bridge point cloud (above: Bridge\_2, below: Bridge\_6)

Table 1 Results of semantic segmentation

|              | Bridge_2     | Bridge_6 |
|--------------|--------------|----------|
| mIoU         | 0.761        | 0.902    |
| Deck IoU     | 0.997        | 0.962    |
| Girder IoU   | 0.977        | 0.967    |
| Pier IoU     | 0.973        | 0.994    |
| Abutment IoU | <b>0.452</b> | 0.873    |
| Bearing IoU  | <b>0.409</b> | 0.713    |

トロピーと Adam を用いた。また「接続関係推定モデル」では、Hungarian 法により総 Intersection over Union (IoU) が最大となるよう、予測インスタンスと正解インスタンスの対応付けを行った。ここで正解インスタンスと対応が得られない予測インスタンスは「誤検出インスタンス False-positive (FP) instances」とラベル付けされる。

3. 実橋梁点群データを用いた検証

本研究の検証は、無償公開されている橋梁点群データセット SemanticBridge<sup>3)</sup>を用いた。実橋梁 20 橋の点群で構成されている。ここでは、20 橋のうち Fig.2 に示す「Bridge\_2」と「Bridge\_6」をテストデータとして、17 橋を訓練データ、1 橋を検証データとした。アノテーションでは、点群の各点に床版・桁・橋脚・橋台・支承のセマンテックラベルと部材インスタンスラベルを付与し、さらに部材インスタンス間の正解接続関係ラベル（隣接行列）を作成した。

Table 1 は、テストデータでのセマンティックセグメンテーションの精度を示したものである。全クラスの IoU 平均値である mIoU は Bridge\_2 で 0.761, Bridge\_6 で 0.902 と異なる分類精度であった。これは特に Bridge\_2 で橋台と支承の IoU が 0.5 より小さく分類精度が低かったことによる。Bridge\_2 では支承部材が小さく各支承の形状が点群上で捉えにくいのに対し、Bridge\_6 では支承形状が比較的明瞭であることによると考えられる。また Bridge\_6 の支承の数は 12 と Bridge\_2 の 25 より少なく、橋脚上で空間的に疎に配置されており、同一のクラスタリング条件でもインスタンス化が安定しやすかったと考えられる。Bridge\_2 では、数多くの支承が密に配置されていることから、25 のうち 13 個の支承インスタンスの見落としがあった。また、予測と正解インスタンスの対応付けでは、FP instances が Bridge\_2 では 38 個、Bridge\_6 では 42 個発生した。

「部材抽出モデル」でインスタンス化した点群を「接続関係推定モデル」に入力するとき、誤検出された FP instance ラベルに分類された点が出力に大きく影響する。そこで本研究では、部材抽出モデルの出力の誤差を学習時に取り込むため、アノテーションで作成した正解インスタンスではなく、予測インスタンスで隣接行列の訓練データを構成する学習「Pred train」を行った。Table 2 に、接続関係推定結果を正解インスタンスに基づく学習「GT train」と比較して示す。Pred train によって、誤接続を大幅に抑制できたことで適合率 Precision は Bridge\_2 で約 3.1 倍、Bridge\_6 で約 4.7 倍に向上した。一方、Pred train での再現率 Recall は GT train よりも低い。これは Pred train では、訓練データ作成時の部材抽出で見落としした部材を含む正解接続関係を定義できないため、その接続を学習できないことが要因と考えられる。

予測された接続行列から接続・非接続を判定して得られた部材接続グラフを、Bridge\_2 と Bridge\_6 それぞれについて Fig.3 と Fig.4 に示す。各図の(a)は推定結果、(b)は正解を示す。ここでは、セマンテッククラスをもつ部材インスタ

Table 2 Connectivity prediction performance for GT-train and Pred-train

|           | Bridge_2     |              | Bridge_6     |             |
|-----------|--------------|--------------|--------------|-------------|
|           | Pred train   | GT train     | Pred train   | GT train    |
| Precision | <b>0.676</b> | 0.220        | <b>0.960</b> | 0.208       |
| Recall    | 0.434        | <b>0.509</b> | 0.889        | <b>1.00</b> |




Fig.3 Bridge component connectivity graph of Bridge\_2




Fig.4 Bridge component connectivity graph of Bridge\_6

ンスがノードとなり、それらが隣接行列に基づいて接続されている。Fig.3 より、Bridge\_2 では、支承部分で付与された FP instance クラスの点群により予測接続グラフの精度は低くなっているが、Fig.4 の Bridge\_6 では支承部の FP instance が少なかったため、比較的妥当な接続グラフを構築することができた。このことから、部材抽出誤差が接続関係推定結果に影響し、接続グラフの精度に影響を与えることが示された。

4. 結論

本研究では、橋梁点群を維持管理で扱える構造情報へ変換するため、部材抽出モデルと接続関係推定モデルを連結し、部材インスタンスをノード、部材接続をエッジとする部材接続グラフを自動生成する手法を提案した。実橋梁点群を用いた検証により、予測インスタンス空間を前提に接続関係を学習する Pred Train により、部材抽出時の誤差がある状況であっても FP instances による誤接続の生成を大幅に抑制することができ、グラフ精度を向上できることを確認した。これにより、点群取得後の部材単位の構造把握の表現を自動で得られる見通しを得た。今後は、特に支承などの小部材の抽出の精度向上に加え、生成グラフを用いて部材抽出結果の修正や、接続の方向つまり支持方向を含む接続関係の多様化をめざし、より高精度かつ実用的な構造表現の生成を目指す。

参考文献

1) Qi, C. R., et al. (2017). Pointnet++: Deep hierarchical feature learning on point sets in a metric space. *Advances in neural information processing systems*, 30.

2) Qi, C. R., Su, H., Mo, K., & Guibas, L. J. (2017). Pointnet: Deep learning on point sets for 3d classification and segmentation. *Proc.IEEE conference on computer vision and pattern recognition* (pp. 652-660).

3) Kellner, M., Cervantes, M. F., Pan, Y., Lu, R., Brilakis, I., & Reiterer, A. (2025). SemanticBridge--A Dataset for 3D Semantic Segmentation of Bridges and Domain Gap Analysis. arXiv preprint arXiv:2512.15369.

**パラメトリックモデルに基づく点群からの3次元モデル構築における  
未想定構造に対する不確実性評価手法（シンポジウム講演概要）**  
**Uncertainty Quantification for Unanticipated Structures in Parametric 3D Model  
Construction from Point Clouds**  
 (Proceedings of Symposium on Applied Mechanics)

石川 大智（東京大・工）    本田 利器（東京大・新領域）    全 邦釘（東京大・工）  
 Taichi ISHIKAWA, The University of Tokyo  
 Riki HONDA, The University of Tokyo  
 Pang-jo CHUN, The University of Tokyo  
 E-mail: tishikawa08c@gmail.com

With the growing availability of 3D sensing technologies, parametric model-based approaches for 3D model construction have gained increasing attention. Although numerous methods employing parametric models have been proposed, approaches that rely on pre-training require robust uncertainty quantification when the input data correspond to structural types not anticipated during training. This study proposes a method for appropriately quantifying uncertainty in parametric model-based 3D model construction from point clouds, particularly for structurally unanticipated inputs. In particular, the introduction of ensemble-based techniques was found to exhibit more desirable uncertainty behavior for inputs that were not observed during training.

## 1. はじめに

デジタルツインを用いた維持管理の効率化や損傷診断の正確化を目的として、橋梁をはじめとしたインフラ構造物における3次元モデルの構築が注目されている。近年、図面や点群といった様々なデータ形式から可能な限り省力的な手法が多数提案されており、その一つの潮流として、パラメトリックモデルと呼ばれるデータフレームの利用に基づく研究が存在する。この枠組みでは、対象の図面や点群に対し、手動での選定や形状最適化、事前学習されたニューラルネットなどを用いて適切なパラメトリックモデルを選定することで、3次元モデルの構築が行われる。

本研究では、パラメトリックモデルの事前学習による手法に着目し、適切なパラメトリックモデル選定時の不確実性評価において、未想定構造に対してロバストな手法の提案を行う。具体的には、ベイズ深層学習に基づく不確実性評価手法に比べ、より柔軟な不確実性評価が可能なアンサンブル手法を用いた不確実性評価手法を構築する。

## 2. パラメトリックモデルによる3次元モデル構築

パラメトリックモデルは、汎用形状の種類（以下、形状クラス）とその形状を特定するのに必要な最小限の独立パラメタ（以下、形状パラメタ）によって規定されるデータフレームである。近年、インフラ分野においてその活用が注目されており、例えば、国土技術政策総合研究所は、橋梁3次元モデルの作成に係る作業コストを省略するためにその活用を推進している。

パラメトリックモデルの事前学習による手法では、橋梁点群を各部位にセグメントし、各部位に対して適切なパラメトリックモデルを探索することを考える。その際、探索を効率化するために、想定する橋梁点群に対し予め適切なパラメトリックモデルを出力するようにニューラルネットを事前学習しておき、それを用いて同定を行う。事前学習にあたり、ニューラルネットが各パラメトリックモデルにおける各パラメタの3次元空間上での意味を学習している必要がある。そこで、候補として用意した複数のパラメトリックモデルから、形状パラメタの値を様々に変化させながら点群として複数サンプリングする。このように生成した点群を入力として、サンプリング時の形状クラス・パラ




Fig. 1 Network Architecture.

メタを予測するようにニューラルネットを学習させることにより、パラメトリックモデルの事前学習が達成される。

## 3. 未想定構造に対する不確実性評価

パラメトリックモデルの事前学習に基づく手法では、学習させておくパラメトリックモデルはエンジニアリングジャッジにより選出されることを想定している。一方で、技術者のミスジャッジや使用先の変更、技術進歩などに起因して、結果として予め想定されるパラメトリックモデルに含まれない構造が対象となる場合も考えられる。そのような場合、入力データは予め学習に用いられたデータに含まれないものとなり、不確実性評価に問題が生じうる。すなわち、統計的な不確実性評価手法では、学習時に存在しないデータについてはどのように振舞うべきかの情報が無いために、学習データ近傍での不確実性しか正しく表現できない。実際、重みを確率変数として扱うことにより確率的推定を可能にする深層学習手法であるベイジアンニューラルネット（BNN）では学習時に存在しないデータに対して不確実性が過信的になりやすいことが指摘されている。

BNNの上述した性質に対して、近年、アンサンブルに基づく不確実性評価手法であるDeep Ensembles<sup>1)</sup>が注目されている。Deep Ensemblesは、同一のニューラルネットを別




Fig. 2 Predictive distributions of shape class and parameters for target bridge point clouds.




Fig. 3 Predictive distributions of shape classes for unknown structures.

の初期値から複数独立に、適切な損失関数を用いて学習させることにより、各モデル出力のアンサンブル平均を用いて不確実性を推定する手法である。本手法の性能の理由については完全に説明されているとはいえないが、重みに特定の分布を仮定しないことや、損失関数の多様なモード探索が可能であることから、学習時に存在しないデータについてより適切な不確実性評価が可能という結果が多数確認されている。そこで本研究では、パラメトリックモデルで未想定な構造に対しより適切な不確実性評価を行うことを目的に、Deep Ensembles を用いた不確実性評価を提案する。

#### 4. 実証分析

レーザー計測を用いて橋梁の点群を取得し、提案手法の有効性について分析した。計測機器には LiDAR 機能を搭載したスマートフォンにおける点群計測ソフト (Scaniverse) を使用した。対象橋梁は、構造形式がボックスカルバート、橋長が約 12.5m、幅員が約 3.3m、高さが約 2.0m である。なお、本橋梁については原形状が単純なため、橋梁全体を 1 つのパラメトリックモデルで表現するが、より複雑な形状では事前の点群セグメンテーションが必要である。

学習データとして使用するパラメトリックモデルは 3 種類とし、直方体形状、逆 T 型形状およびボックスカルバート形状を設定した。はじめに、各形状における端点の座標を定義し、それらからメッシュデータを作成することにより、点数 1,000 の一様サンプリングを通じて表面から点群のサンプリングを行った。その際、各種類の点群の形状パラメタの値を様々に変更しつつ、5,000 個ずつ作成して学習データとした。各形状パラメタの摂動は、対象橋梁の寸法を包含するように決定した幅をもつ一様分布に従って与えることとした。Fig.1 に、実証分析で用いたモデルの構造を示す。活性化関数は、形状クラスを推定する最終層で softmax 関数、各形状パラメタの平均および分散 (の対数) を推定する最終層で恒等関数とし、それ以外の層では ReLU を用いた。学習におけるエポック数は 100、バッチサイズは 32 とし、重みの最適化手法には Adam を用いた。

Fig.2 に、対象橋梁の形状クラス・パラメタの予測分布の推定結果を示す。Fig.2 においては、形状クラスの予測確

率が最も高く算出されたボックスカルバート形状を構成する 9 つの形状パラメタの予測分布のみを示している。形状パラメタの予測分布に付記した値はそれぞれ、青色が各分布における最頻値、緑色が各分布における平均値を表している。形状パラメタについて、最頻値を用いると、橋軸方向の奥行  $d = 11.85\text{m}$ 、高さ  $H + h_1 + h_2 + 2 \times H_H = 2.0\text{m}$ 、幅員  $W + t_1 + t_2 + 2 \times W_H = 3.68\text{m}$  として計算されるため、対象橋梁と比較すると、ある程度合理的な形状が推定されている。なお、推定される不確実性の比較のため、BNN の代表的手法である Monte Carlo Dropout<sup>2)</sup> による予測分布の算出結果も併記している。Fig.2 より、非主要なパラメタを含め、両者は近い推定結果となっていることがうかがえる。すなわち、対象橋梁の形状クラス・パラメタが学習データ内に含まれる場合は、どちらの手法でも不確実性の推定に大きな違いはない結果となった。

また、未想定構造に対する不確実性評価に関しても検討を行った。学習データに含まれない構造として、I 型構造と (重力式) 擁壁構造の 2 種類を用いた。これら 2 種類の形状から、上述したプロセスと同様に、点群を作成した。この際、I 型構造については高さパラメタのみを変化させて、短柱と長柱の 2 種類を、擁壁構造については奥行パラメタのみを変化させて、大擁壁と小擁壁の 2 種類を用意した。これら 4 種類の点群を上記で学習済みのモデルに入力し、形状クラス・パラメタの予測分布の算出を行った。

Fig.3 に、各種類の点群に対し推定された形状クラスの予測分布を示す。Fig.3 より、どの形状においても Deep Ensembles を用いた場合の方が、予測時に曖昧さが生じていることがうかがえる。パラメトリックモデルで未想定な構造に対しては、予測のばらつきが生じ大きな不確実性が推定されることが期待されるが、Deep Ensembles による予測分布の推定の方がより望ましいという結果となった。

#### 5. おわりに

本研究では、パラメトリックモデルの事前学習に基づく点群からの 3 次元モデル構築において、未想定構造に対するロバストな不確実性評価手法を提案した。今後の課題として、より大規模な橋梁点群への適用の蓄積があげられる。

**謝辞:** 本研究 (の一部) は、内閣府総合科学技術・イノベーション会議の戦略的イノベーション創造プログラム (SIP) 第 3 期「スマートインフラマネジメントシステムの構築」JPJ012187 (研究推進法人: 土木研究所) によって実施された。ここに記して感謝の意を表する。

#### 参考文献

- 1) Lakshminarayanan, B., Pritzel, A., and Blundell, C.: Simple and scalable predictive uncertainty estimation using deep ensembles, *Advances in NIPS*, 30, 2017.
- 2) Gal, Y. and Ghahramani, Z.: Dropout as a Bayesian approximation: Representing model uncertainty in deep learning, *Proceedings of the 33rd ICML*, pp.1050-1059, 2016.

企画セッション | 企画セッション (応用数理・AIの活用～デジタルツインから量子計算まで～)

■ 2026年5月16日(土) 16:25～17:25 | ■ B会場(環境棟：3階講義室)

## 応用数理・AIの活用 (2)

座長:北原 優(北海道大学)

16:25～16:40

[12016] インフラデジタルツインのためのMCPによるデータ連携・ツール共有・知識共有化 (シンポジウム講演概要)

\*本田 利器<sup>1</sup> (1. 東京大学)

---

16:40～16:55

[12017] マルチスケール大気モデル (MSSG) による微気象解析のための入力データの自動構築 (シンポジウム講演概要)

\*本田 和也<sup>1</sup>、中瀬 仁<sup>1</sup>、松田 景吾<sup>2</sup>、杉山 徹<sup>2</sup>、栗原 祐也<sup>3</sup>、亀田 敏弘<sup>3</sup>、清野 友規<sup>4</sup> (1. 東電設計株式会社、2. 海洋研究開発機構、3. 筑波大学、4. 横浜国立大学)

---

16:55～17:10

[12018] 都市規模の地震被害評価のための最適センサー配置と逐次ベイズ更新 (シンポジウム講演概要)

\*湯 東暘<sup>1</sup>、Sukulthanasorn Naruethep<sup>1</sup>、野村 怜佳<sup>1</sup>、郭 佳<sup>2</sup>、大野 晋<sup>1</sup>、野島 和也<sup>3</sup>、森 篤史<sup>3</sup>、佐藤 誠一<sup>3</sup>、櫻庭 雅明<sup>3</sup>、寺田 賢二郎、森口 周二 (1. 東北大学、2. 京都大学、3. 日本工営株式会社)

---

17:10～17:25

[12019] 不均一分散変分オートエンコーダに基づく静的データ融合のための生成フレームワーク (シンポジウム講演概要)

\*ダルマシリ ミゲルアラチラゲカスンマドゥサンカ<sup>1</sup>、本田 利器<sup>1</sup> (1. 東京大学)

## インフラデジタルツインのための MCP によるデータ連携・ツール共有・知識共有化 (シンポジウム講演概要)

### MCP-based Data Integration, Tool Sharing, and Knowledge Sharing for Infrastructure Digital Twins (Proceedings of Symposium on Applied Mechanics)

本田 利器 (東京大学)  
Riki HONDA, University of Tokyo  
E-mail: rhonda@k.u-tokyo.ac.jp

The data platform for digital twins of infrastructure should be capable to manage the relationships among highly diverse data sets. Considering the property of infrastructure data, we developed a data integration platform using the MCP protocol to connect data and tools developed in the SIP project, and conducted a proof-of-concept (POC) targeting several use cases. The POC demonstrated that establishing these relationships as procedural knowledge when connecting data and tools via MCP effectively supports the stable operation of large language models (LLMs).

#### 1. はじめに

社会インフラの維持管理において、デジタルツイン技術や BIM/CIM の導入が推進されている。国土交通データプラットフォーム等のオープンデータ整備が進むが、データは公開するだけでは活用されず、科学技術を反映させる環境が必要である<sup>1)</sup>。国土交通データプラットフォームや xROAD 等により多様なデータが蓄積されつつあるが、インフラのデータは長年にわたる蓄積があるため、紙ベースのデータであることも多く、また、データフォーマットや用途が多様であるため、汎用の共通フォーマットの策定は困難であり、用途に応じたデータスキーマを定めた上で、それらを相互に変換・接続できるデータ連携基盤が求められている。

そのような背景をふまえ、SIP スマートインフラマネジメントシステムの構築におけるサブ課題 D「サイバー・フィジカル空間を融合するインフラデータベースの共通基盤の構築と活用」(以下、「SIP プロジェクト」)では、デジタルツインの運用基盤の構築、多様なインフラデータの自動変換基盤技術、DuCOM-COM3<sup>2)</sup>等によるシミュレーションを用いた維持管理のためのデジタルツイン、都市環境評価のためのデジタルツインが研究課題となっている<sup>1)</sup>。

本報告では、SIP プロジェクトで開発されたデータやツールを MCP で接続するデータ連携基盤を構築し、ユースケースを想定した概念実証を通じて、手順書・知識の整備と共有化について検討した結果を述べる。

#### 2. MCP によるデータ連携

SIP プロジェクトでは、汎用の共通データフォーマットを策定するのではなく、用途ごとに特化したデータスキーマを定め、それらを相互変換することでデータの接続性を確保するアプローチを提案している。データが有効に活用されるためには、一般的なメタデータに加え、データの「素性」(例えば、3D モデルやシミュレーション結果がどのデータから、どのように生成されたのか、等)も重要な情報である。そのため、データ連携においては、他のデータとの関連性やデータの処理方法などの情報も保持することが求められる。

そのような関係性は非常に多様であり、かつ動的に変化するため、事前にスキーマを固定するリレーショナルデータベースでの管理は容易ではない。近年はナレッジグラフを利用して LLM の検索を強化する GraphRAG 等の手法も広まっている。一方、2024 年 11 月に Anthropic 社が公開した MCP (Model Context Protocol)<sup>2)</sup>は、LLM と外部ツール・データソースを接続する標準プロトコルであり、多様なデータスキーマやツールをブ

ロコルレベルで統合できる基盤技術として普及が進んでいる。MCP を用いることで、LLM が自然言語の指示に基づいて異種データの取得・変換・可視化を自律的に連携できる。

インフラのデータは点検記録、3D モデル、シミュレーション結果、センシングデータなど形式やスキーマが非常に多様である。このような異種データを統合的に扱うためには、個々のデータ形式の差異を柔軟に解釈できる仕組みが求められる。そこで、LLM と外部ツール・データソースの接続プロトコルである MCP を利用し、LLM が異種データ間の形式・構造・意味の違いを解釈しながらデータを連携する方法を検討する。

#### 2.1 データ連携基盤

データ連携基盤は、MCP Host (LLM アプリケーション)、MCP Client (接続管理)、MCP Server (ツール・データ提供) の 3 要素で構成されるものとした。

MCP Server 群はデータ取得層 (点検データ・統計・災害リスク・道路ネットワーク等)、分析・変換層 (3D モデリング・データ形式変換)、可視化・出力層 (地図・シミュレーション可視化)、知識・検索層 (手順書・技術文書の横断検索) の 4 層構成で設計されている。LLM はユーザーの自然言語指示を受けてタスクを分解し、適切な MCP サーバーを自律的に選択・連携する。

#### 2.2 開発ツールの共有

MCP に対応した CAD ソフトウェアを活用することで、LLM が既存の点検データやテンプレート、手順書を参照しながら橋梁の諸元データ(スパン長、幅員、桁高等)に基づく 3D モデルを簡易に作成できる。本プロジェクトでは FreeCAD MCP サーバーを用いてパラメトリックモデルの自動作成や FEM 解析の実行を検証した。

データ形式変換については、SIP プロジェクトで作成された XML 形式の形状データから IFC や GLB 等の 3D モデル形式への変換パイプラインを MCP サーバーとして実装した。座標系や要素番号体系はデータソースごとに異なるため、その違いを手順書に留意事項として記載し、LLM が変換時に参照できるようにした。

#### 2.3 知識の共有化と活用

データ間の関係性等を管理するため、これを記述する知識を LLM が解釈することを想定したドキュメントとして保持する。これにより、リンクの方向性やラベルのような情報に加え、データ処理に用いるツールやコンテキストなどの詳細な情報を保持

できる. 具体的には, LLM が活用する知識を宣言的知識 (Declarative: 事実・定義)と手続き的知識 (Procedural: 手順・操作)に分類し<sup>4)</sup>, マークダウン形式で体系化した. これらの知識は MCP サーバーを通じて LLM がタスク実行時に適切な手順書や定義を参照できる構成とした.

MCP によるデータ連携環境の適用範囲を示すため, 6 つのユースケース(3D モデルによる点検可視化, 洪水シミュレーション可視化, FEM 解析, 道路ネットワーク分析, 熱中症リスク分析, BIM/CIM 文書検索)を設定し, 各ユースケースの実行を通じて手順書・知識の有用性を検証した. 手順書や知識は再利用可能な部品として整備されており, LLM がこれらを新たに組み合わせることで未知のユースケースにも対応できる可能性を示した.

3. 概念実証の結果と課題

概念実証では, Claude Code (CLI) を MCPHost として複数の MCP サーバーと知識ベースを用いた検証を実施した. 単一 MCP サーバーの呼び出しは安定して動作し, 複数サーバーの連鎖(橋梁検索→点検データ取得→3D モデル作成等)も手順書を参照することで動作を確認した. 手順書がない場合には LLM の判断にばらつきが生じるケースがあり, 手順書・知識の整備が精度向上に寄与することを確認した.

Fig. 1 にアーキテクチャの概要を示す. 既存のデータベースや SIP プロジェクトで開発した技術を連携させる構成となっている. Fig. 2 に MCP サーバーの UI 案を示す. データ, ツール・手順書のそれぞれの MCP サーバが管理されている.

Fig. 3 にユースケース別マップビューアを示す. UC1 (3D モデル点検可視化), UC2 (洪水シミュレーション), UC3 (FEM 解析), UC4 (道路ネットワーク), UC5 (熱中症リスク)の各データ分布を地図上に可視化し, 空間的な対象範囲を確認できる. ただし, 大容量データ処理時のコンテキストウィンドウの制約, MCP サーバー間のデータ形式の




Fig. 1 MCP-based data integration and analysis orchestration architecture.



Fig. 2 Integrated dashboard of MCP servers: data, tools and knowledge.




Fig. 3 Use case map viewer showing spatial distribution of UC1-UC5 data.

不一致, LLM 判断のばらつき等の課題があることも明らかとなった.

4. まとめ

MCP プロトコルを基盤として, SIP プロジェクトで開発されたデータやツールを接続するデータ連携基盤を構築し, ユースケースを想定した概念実証を行った. 概念実証を通じて, MCP によるデータ・ツールの接続において, その関係性を手順書 (知識) として整備することで LLM の安定的な動作に有効であることが示された. 今後, 新しいユースケースに対応してデータやツールが開発・整備されていく. その際, それらに対応する手順書 (知識) として再利用可能な情報として併せて整備していくことが, データ連携基盤の実用化に向けて重要である.

謝辞 本研究は, 内閣府総合科学技術・イノベーション会議の戦略的イノベーション創造プログラム (SIP) 第 3 期「スマートインフラマネジメントシステムの構築」JPJ012187 (研究推進法人:土木研究所) によって実施された.

参考文献

1) 本田利器: スマートインフラマネジメントのためのデジタルツイン環境構築技術, 第 27 回応用力学シンポジウム講演概要, 24010-14-01, 土木学会, 2024.

2) 杉崎光一, 全邦釘, 阿部雅人: Model Context Protocol(MCP)のインフラ・防災分野への適用に関する検討, AI・データサイエンス論文集, vol.6, No.J4, pp.37-45, 2025.

3) Maekawa, K., Ishida, T. and Kishi, T.: Multi-scale modeling of structural concrete, Taylor & Francis, 2008.

4) 杉崎光一, 阿部雅人, 全邦釘: 大規模言語モデルの専門領域への適用に関する検討, AI・データサイエンス論文集, vol.4, No.J3, pp.474-481, 2023.

5) 随海通, 陳瑜, 全邦釘: MCP 基盤の自然言語インタフェースを用いた橋梁デジタルツイン構築手法の提案と初期検討, AI・データサイエンス論文集, vol.6, No.J3, pp.616-623, 2025.

6) 阿部雅人, 杉崎光一, 全邦釘: インフラマネジメントのためのインフラ OS に求められる基本機能に関する考察, AI・データサイエンス論文集, vol.3, No.J2, pp.608-620, 2022.

# マルチスケール大気モデル (MSSG) による微気象解析 のための入力データの自動構築 (シンポジウム講演概要) Automatic Generation of Input Data for micrometeorological analysis using Multi-Scale Simulator for the Geoenvironment (Proceedings of Symposium on Applied Mechanics)

本田 和也 (東電設計株式会社) 中瀬 仁 (東電設計株式会社)  
松田 景吾 (海洋研究開発機構) 杉山 徹 (海洋研究開発機構)  
栗原 祐也 (筑波大学・シス情) 亀田 敏弘 (筑波大学・シス情)  
清野 友規 (横浜国立大学・都市イノベ)

Kazuya HONDA, TEPSCO Hitoshi NAKASE, TEPSCO  
Keigo MATSUDA, JAMSTEC Toru SUGIYAMA, JAMSTEC  
Yuya KURIHARA, University of Tsukuba Toshihiro KAMEDA, University of Tsukuba  
Tomoki KIYONO, Yokohama National University  
E-mail: kazuya-honda@tepsco.co.jp

To conduct micrometeorological analysis using the multiscale atmospheric model, Multi-Scale Simulator for the Geoenvironment (MSSG), we developed an automated method for generating digital twins. This method utilizes 3D urban model data (Project PLATEAU) linked to the Ministry of Land, Infrastructure, Transport and Tourism's National Land and Transportation Data Platform. The automated generation process reduces manual labor and effort. Furthermore, to enable micrometeorological calculations in areas where PLATEAU datasets are not sufficient, we have developed a system that automatically generates input data for these calculations from other available datasets.

## 1. はじめに

近年、温暖化の影響により、夏場には毎年多くの熱中症被害が発生している。熱中症の被害リスクを詳細に計算するためには、建物等の影響を考慮した微気象まで計算可能な気象モデルが必要である。海洋研究開発機構(JAMSTEC)の開発する MSSG (Multi-Scale Simulator for the Geoenvironment) <sup>1)</sup>は、全球スケールから領域スケール、都市スケールまでを計算可能なマルチスケール大気海洋結合モデルであり、建物や樹冠の3次元形状を考慮した数m解像度の微気象計算が可能である <sup>2)</sup>。

著者らは、微気象計算に要する労力を軽減するため、国土交通省の国土交通データプラットフォームにも紐づけられる3D都市モデルデータ (Project PLATEAU) から MSSG の微気象計算用のデジタルツインを自動作成する方法を構築した。しかし、PLATEAU の3D都市モデルデータの整備されている地域は限定的であり、整備されていない地域では、他の情報から入力データを作成する必要がある。

本稿では、PLATEAU の3D都市モデルデータの未整備の地域であっても、他のデジタルデータから微気象計算用のデジタルツインを自動作成するシステムを構築した。

## 2. MSSG 微気象計算のためのデジタルツイン

データの自動変換・統合技術として、理化学研究所では DPP (Data Processing Platform) が開発されている。筆者らは、国土交通省の PLATEAU データを DPP に読み込み、MSSG の微気象解析に利用可能なデータ形式で出力する機能を持つライブラリを構築した。MSSG の微気象計算に必要な地理入力データには、建物高さ、標高、土地利用区分、樹木高さについてのグリッドデータがある。PLATEAU の3D都市モデルデータには、これらのデータを定義可能なフォーマットが定められている。PLATEAU データにこれらの情報が整備されていない場合には、それぞれ他のデータで代替する必要がある。

## 3. 代替データによるデジタルツインの構築

既存のライブラリは、PLATEAU を構成する形状と属性情報から MSSG の入力データを自動構築する機能を有している。そのため、代替データから必要な形状と属性情報を読み込むことで、比較的容易に MSSG の入力データを代替データから作成する機能を持たせることができる。

国土地理院は、基盤地図情報の基本項目として、建物の外周線データを GML 形式で公開している。建物外周線データから建物の平面形状および建物種別を把握できる。建物高さについては、一般に公開される情報は少ないため、建物種別に応じて建物高さを仮定することで、各計算グリッドにおける建物高さを設定する。Fig.1 に PLATEAU と基盤地図情報を基に作成した建物高さデータをそれぞれ示す。本手法では建物種別ごとに一定の建物高さを仮定するため、高層建物の多い都市部では建物高さの誤差が大きくなるが、PLATEAU の整備されていない地域では誤差は比較的小さいと考える。

国土地理院は、基盤地図情報の一部として、数値標高モデルを GML 形式で公開している。数値標高モデルから標高点の座標と標高を読み込むことで、各計算グリッドにおける標高を設定する。Fig.2 に PLATEAU と基盤地図情報を基に作成した標高データをそれぞれ示す。

JAXA の高解像度土地利用土地被覆図は、10m 解像度の土地利用、土地被覆のデータを GeoTIFF 形式で提供している。MSSG における土地利用区分と高解像度土地利用土地被覆図における区分を対応付けすることで、計算グリッドごとに土地利用区分を設定する。Fig.3 に PLATEAU と高解像度土地利用土地被覆図を基に作成した土地利用データをそれぞれ示す。

土地利用として定義されている樹木に対して樹木の高さを仮定することで、樹木高さを設定する。PLATEAU データに整備されている樹木データは現状では極めて少なく、

本手法によって樹木を仮定することでより多くの樹木を表現することが微気象計算において重要である。また、MetaのHigh Resolution Canopy Height Mapsを利用することで、樹木データをより詳細に表現することが可能である。




Fig.1 Building height based on PLATEAU (left) and GSI (right)




Fig.2 Elevation based on PLATEAU (left) and GSI (right)




Fig.3 Land use based on PLATEAU (left) and JAXA (right)

#### 4. 実在街区を対象とした微気象計算

MSSGはマルチスケールの大気モデルであるため、気象庁の数値予報モデルを境界値として複数回のダウンスケーリングを行うことで、数メートル解像度の微気象計算を実施し、熱中症危険度の指標であるWBGT (Wet Bulb Globe Temperature) を計算することが可能である。本計算対象地域では、PLATEAUの建物データ、標高データは整備されているものの、土地利用データ、樹木データは整備されていないため、土地利用データはJAXAの高解像度土地利用土地被覆図、樹木データはMetaのHigh Resolution Canopy Height Mapsを基に作成した。Fig.4に作成した土地利用データと樹木高さデータを示す。




Fig.4 Land use (left) and Tree height (right)

計算対象地域における微気象計算の結果として、風速・風向の分布とWBGTの分布をFig.5に示す。5m解像度でモデル化した標高、建物、樹木などの影響による局所的な風環境、熱環境の違いを表現することで、局所的な熱中症危険度の違いを評価している。Fig.6に現地で計測したWBGTと計算結果との比較を示す。本計算では、現地計測と計算結果は比較的良好な関係を示した。




Fig.5 Result of wind velocity (left) and WBGT (right)




Fig.6 Comparison of MSSG and measurement (WBGT)

#### 5. おわりに

PLATEAUからMSSGの微気象計算用のデジタルツインを自動作成する既存のライブラリに、日本全国で活用可能なデジタルデータを活用する機能開発を実施した。本システムによって、日本全国どの地域であっても微気象計算を実施し、熱中症の危険度を評価できる。特に、現状のPLATEAUに整備が進んでいない樹木データに関しては、他のデータで代替することで、より実際の都市環境に近い条件の入力データの作成が可能である。都市部においては、PLATEAUの建物データを他のデータと組み合わせることで精度の高いモデルを構築できる。これらの代替データを活用するための機能拡張は、既存のライブラリを活用することで、比較的に容易に実施することが可能であった。

**謝辞：**本研究の一部は、内閣府総合科学技術・イノベーション会議の戦略的イノベーション創造プログラム (SIP) 第3期「スマートインフラマネジメントシステムの構築」JPJ012187 (研究推進法人:土木研究所) によって実施された活動の一環である。

#### 参考文献

- 1) Takahashi, K., Onishi, R., Baba, Y., Kida, S., Matsuda, K., Goto, K., Fuchigami, H., Challenge toward the prediction of typhoon behavior and down pour, J. Phys. Conf. Ser., 454, 012072 (2013).
- 2) Matsuda, K., Onishi, R., Takahashi, K., Tree-crown-resolving large-eddy simulation coupled with three-dimensional radiative transfer model, Journal of Wind Engineering & Industrial Aerodynamics, Vol. 173, pp. 53-66 (2018).

# Optimized Sensor Placement and Sequential Bayesian Updating for City-Scale Seismic Damage Assessment (Proceedings of Symposium on Applied Mechanics)

Dongyang Tang, Tohoku University  
Naruethep Sukulthanasorn, Tohoku University  
Reika Nomura, Tohoku University  
Jia Guo, Kyoto University  
Susumu Ohno, Tohoku University  
Kazuya Nojima, Nippon Koei Co., Ltd.  
Atsushi Mori, Nippon Koei Co., Ltd.  
Seiichi Sato, Nippon Koei Co., Ltd.  
Masaaki Sakuraba, Nippon Koei Co., Ltd.  
Kenjiro Terada, Tohoku University  
Shuji Moriguchi, Tohoku University  
E-mail: tang.dongyang.r3@dc.tohoku.ac.jp

This study proposes a framework for assessing the seismic risk of buildings in large-scale urban area. City-scale numerical simulations and sensor network are integrated to update building-specific fragility functions. The proper orthogonal decomposition (POD) technique plays a crucial role to analyze numerical simulation data. The POD-based approach helps to represent large-scale simulation results in a more compact and meaningful way, a crucial step in understanding seismic impacts. The framework also highlights the importance of sparse sensor distribution. Furthermore, this study uses cloud analysis and Bayesian updating to update the fragility functions of buildings based on sensor data. It first creates fragility functions for all buildings based on cloud analysis using numerical simulation data, and then progressively refines them by incorporating sensor data through Bayesian inference. This dual-stage approach allows for a rapid risk assessment of all buildings in a target area, with continuous improvements to fragility functions by the sensor data.

## 1. Introduction

This study introduces a framework for assessing earthquake risk in large-scale urban area. It integrates numerical simulations and sensor data to evaluate building seismic responses. The Stochastic Green Function and Integrated Earthquake Simulation (IES)<sup>(2)</sup> methods generate data for analysis. Fragility functions, representing building vulnerability, are derived from these simulations and refined with sensor network, employing techniques Proper orthogonal decomposition (POD), sparse sensing technology, and Bayesian updating. The effectiveness of the proposed framework is examined with Sendai City as the target area.

## 2. Numerical simulation

In the numerical simulation of seismic motion, from earthquake fault to engineering bedrock and then to the surface, two main methods are employed to assess the response of surface structures: the Stochastic Green's Function and the Integrated Earthquake Simulator (IES)<sup>(2)</sup>. The Stochastic Green's Function method is an extension of the empirical Green's Function approach, introduced by Irikura<sup>(1)</sup>, utilizing observed records to account for subsurface structures' effects on seismic waves. It is particularly useful when suitable observed records are unavailable. IES, integrated with a Geographic Information System (GIS), integrates earthquake motion simulation with structural and seismic response simulation. It involves generating earthquake waves, evaluating their impact on structures, and analyzing evacuation and crisis management after an earthquake. By adjusting the fault model, various scenarios are created for both methods, facilitating the generation of training and validation datasets for seismic response analysis.

## 3. Sparse sensor network for monitoring

Proper orthogonal decomposition (POD) extracts dominant spatial modes from data based on singular value decomposition (SVD)<sup>(3)</sup>. Given a data matrix  $\mathbf{Y}$ , its SVD is

$$\mathbf{Y} = \mathbf{U}\mathbf{\Sigma}\mathbf{V}^T, \quad (1)$$

and each snapshot  $\mathbf{y}_i$  can be approximated by a truncated expansion

$$\mathbf{y}_i \approx \sum_{j=1}^r z_{ij} \mathbf{u}_j, \quad (2)$$

where  $\mathbf{u}_j$  is the  $j$ -th POD mode and  $z_{ij}$  is its corresponding modal coefficient for case  $i$ .

Using the retained modes, sparse sensing is formulated as a linear measurement model:

$$\mathbf{y} = \mathbf{H}\mathbf{U}\mathbf{z} = \mathbf{C}\mathbf{z}, \quad (3)$$

where  $\mathbf{y} \in \mathbb{R}^p$  is the observation vector,  $\mathbf{H} \in \mathbb{R}^{p \times n}$  is the sensor location (selection) matrix,  $\mathbf{U} \in \mathbb{R}^{n \times r}$  contains the retained POD modes,  $\mathbf{z} \in \mathbb{R}^r$  is the latent state, and  $\mathbf{C} = \mathbf{H}\mathbf{U} \in \mathbb{R}^{p \times r}$  is the measurement matrix. Observations are assumed to be contaminated by Gaussian noise  $N(0, \sigma^2 \mathbf{I})$ . The latent state is estimated via the pseudo-inverse<sup>(4)</sup>:

$$\hat{\mathbf{z}} = \begin{cases} \mathbf{C}^T(\mathbf{C}\mathbf{C}^T)^{-1}\mathbf{y}, & p \leq r, \\ (\mathbf{C}^T\mathbf{C})^{-1}\mathbf{C}^T\mathbf{y}, & p > r. \end{cases} \quad (4)$$

Sensor locations are optimized to reduce the uncertainty of  $\hat{\mathbf{z}}$ . Specifically, we adopt a D-optimal criterion, i.e., selecting  $\mathbf{H}$  to maximize the information content of  $\mathbf{C}$  (equivalently, minimize the estimation error covariance). A genetic algorithm is used to search for the optimal sparse sensor configuration in this study.

## 4. Sequential update of a damage assessment model

The sparse sensor network provides partial observations of earthquake input and structural response, such as intensity measures (IM) and engineering demand parameters (EDP). To map these measurements to building level damage probabilities, we use fragility functions derived via cloud analysis<sup>(5)</sup>:

$$P_f(EDP \geq LS \mid IM) = \Phi\left(\frac{\ln IM - \ln \eta}{\beta}\right), \quad (5)$$

where  $\Phi(\cdot)$  is the standard normal CDF, and  $\eta$  and  $\beta$  are the median and dispersion.

To support city-scale updating, we model the IM–EDP relation in log space with a Bayesian hierarchical regression<sup>6)</sup>:

$$\ln EDP_{j,i} = \alpha_j + \beta_j \ln IM_{j,i} + \varepsilon_{j,i}, \quad \varepsilon_{j,i} \sim \mathcal{N}(0, \sigma^2). \quad (6)$$

Buildings of the same structural type share information through type-level priors on  $(\alpha_j, \beta_j)$  (partial pooling), which stabilizes estimates when per-building data are limited or noisy (e.g., when full-field responses are inferred from sparse measurements). For each limit state  $LS$ , the posterior of  $(\alpha_j, \beta_j, \sigma)$  is converted to the corresponding fragility parameters  $(\eta, \beta)$  using the standard cloud-analysis mapping.

Exact inference is intractable for an urban inventory, so we use mean-field variational inference. When a new earthquake provides additional data  $\mathbf{D}_t$ , we update the variational posterior sequentially by treating the previous approximation as a predictive prior:

$$q_t = \arg \max_q \mathbb{E}_q[\log p(\mathbf{D}_t | \theta)] - \text{KL}(q(\theta) \parallel q_{t-1}(\theta)). \quad (7)$$

This event by event update avoids refitting on the full historical dataset while continuously refining the fragility parameters in Eq. (5) as new observations become available.

## 5. Workflow of the proposed sequential risk assessment framework

The proposed framework operates through repeated predict update cycles. At step  $t$ , a spatial IM field (e.g., PGA) is obtained and used to generate predictive damage estimates based on the variational posterior from step  $t-1$ . When new observations are available, sequential variational inference updates the posterior by treating the previous approximation as a predictive prior and conditioning on the new data, yielding updated damage estimates.

Figure 1 summarizes the workflow across multiple update steps: the first row shows the IM (PGA) maps, the second row shows predictive damage estimates before the current update, and the third row shows the updated damage estimates after assimilating the current observation. In this study, only one target building typology is included in the evaluation and updating, buildings outside this typology are excluded and shown as gray points.




Fig. 1 Workflow illustration of the proposed sequential damage assessment framework.

## 6. Conclusion

This study presents a novel method for assessing and updating seismic risk profiles of urban buildings, suggesting a path forward for making cities safer and more resilient to earthquakes through technological and methodological advancements. The result underscores the importance of integrating numerical, and highlights the need for extensive data collection to further refine fragility functions, suggesting future research directions that include adjusting fault parameters for broader scenarios and incorporating more detailed intensity measures.

## References

- 1) Irikura, K.: Prediction of strong acceleration motion using empirical Green's function, Proc. 7th Japan Earthq. Eng. Symp. vol. 151, 1986.
- 2) Hori, M.: Introduction to computational earthquake engineering, 2011.
- 3) Liang, Y. C., et al.: Proper orthogonal decomposition and its

applications—Part I: Theory, Journal of Sound and Vibration 252.3, pp.527-544, 2002.

- 4) Nakai, K., Yamada, et al.: Effect of Objective Function on Data-Driven Greedy Sparse Sensor Optimization, in IEEE Access, vol. 9, pp. 46731-46743, 2022
- 5) Saouma, V.E., Hariri-Ardebili, M.A.: Fragility Functions, In Aging, Shaking, and Cracking of Infrastructures, Springer, Cham, 2021.
- 6) Gelman, A., Carlin, J.B., Stern, H.S., Rubin, D.B., Dunson, D.B., Vehtari, A.: *Bayesian Data Analysis*, 3rd ed., Chapman and Hall/CRC, Chapter 15, pp. 381–402, 2013.
- 7) Li, Jian and Spencer, Billie F., et al.: Bayesian Updating of Fragility Functions Using Hybrid Simulation, Journal of Structural Engineering, vol. 139, no. 7, pp. 1160-1171, 2013.
- 8) Irikura, K., Hiroe, M.: Recipe for Predicting Strong Ground Motion from Crustal Earthquake Scenarios, Pure and Applied Geophysics, vol. 168, no. 1, pp. 85-104, 2011

# A Generative Framework for Static Data Fusion based on Heteroscedastic Variational Autoencoders (Proceedings of Symposium on Applied Mechanics)

M. A. K. M. DHARMASIRI, The University of Tokyo  
Riki HONDA, The University of Tokyo  
E-mail: makmd@g.ecc.u-tokyo.ac.jp

Static data fusion could be used for integrating multi-source sensor measurements into a unified representation with reduced variance. This paper proposes a generative framework for static data fusion without any limitations on the nature of the noise distributions based on heteroscedastic Variational Autoencoders (VAEs) that treats likelihood derivation as a generative noise modeling task. The methodology comprises of two distinct phases: an offline stage where a VAE learns the underlying noise distribution directly from deviation vectors, and an online inference phase that utilizes an Importance Weighted Autoencoder (IWAE) structure to compute the posterior distribution. Numerical verification using the fusion of two 10-dimensional multivariate logistic datasets demonstrates that the proposed framework serves as a robust surrogate for the likelihood function. The results show that high-fidelity posterior estimation is achievable even within a compressed latent space equivalent to only 30% of the original feature dimensionality. This approach offers a robust advantage for real-world Bayesian inference by bypassing the need for explicit parametric equations in complex, high-dimensional environments and overcoming limiting assumptions based on Gaussianity.

## 1. Introduction and Motivation

Measurements acquired from real-world sensors are inherently noisy. An appropriate method to handle this uncertainty is to treat the collected samples as instantiations of specific probability distributions. When analyzing concurrent readings from an array of sensors, static data fusion can be used to merge this information to yield an estimate that is significantly more precise than any individual measurement. In the context of digital twins, static data fusion is particularly applicable when multiple data sources describe the same physical phenomenon or operating condition, and the objective is to integrate these views into a unified representation with reduced variance.

Generative Machine Learning (ML) methods have been applied to address various real world problems. A particular application that is similar to the problem that we are trying to address in this study is data assimilation (Chen et al.<sup>1)</sup>). In ML-assisted data assimilation for dynamical systems, the state is first advanced in a forecast/prediction step and then updated in an analysis/correction step when new observations become available. For high-dimensional systems, Cheng et al.<sup>1)</sup> emphasize that data assimilation could be accomplished in the latent space (called latent space DA) leading to computational efficiencies. In this sense, latent-space DA is a recursive state-estimation framework for time-evolving systems, in contrast to the static representation-level fusion of multiple views, which is the focus of this study.

Bayesian inference provides the foundational mathematics for integrating prior beliefs with new observations via Bayes' rule. Yet, characterizing the exact likelihood function becomes a major issue when the data exhibits complex, non-Gaussian traits. To resolve this, the proposed methodology treats the likelihood derivation as a generative noise modeling task. By deploying a heteroscedastic Variational Autoencoder (VAE) (Kingma and Welling<sup>2)</sup>), i.e., a VAE with a stochastic encoder and a stochastic decoder, the system learns the underlying noise distribution directly from the data, acting as a surrogate for traditional parametric equations.

## 2. Proposed Generative Methodology

Suppose data is available from two sources,  $X$  and  $Y$ . Then, the posterior distribution  $p(x|\bar{y})$  could be computed following the Bayes' theorem,

$$p(x|\bar{y}) = \frac{p(\bar{y}|x)p(x)}{p(\bar{y})}; \quad p(\bar{y}) = \int p(\bar{y}|x)p(x)dx \quad (1)$$

Here  $\bar{y}$  is the mean of a set of new observations ( $y^i \in Y$ ),  $\{y^1, \dots, y^M\}$  and  $p(\bar{y}|x^n)$  is the likelihood. The prior is the empirical distribution ( $x^i \in X$ ),  $\{x^1, \dots, x^N\}$  given by

$$p(x) = \frac{1}{N} \sum_{n=1}^N \delta(x - x^n) \quad (2)$$

Substituting Eq. 2 into Eq. 1 results in the following posterior

$$p(x|\bar{y}) = \sum_{n=1}^N \beta^n \delta(x - x^n) \quad (3)$$

where the posterior weights  $\beta^n$  are given by

$$\beta^n = \frac{p(\bar{y}|x^n)}{\sum_{j=1}^N p(\bar{y}|x^j)} \quad (4)$$

The proposed method discards the requirement for explicit likelihood equations, substituting them with a machine learning-based density estimator based on the deviator vector, i.e., the deviation  $v^n$  between the observation mean ( $\bar{y}$ ) and a prior state  $x^n$ .

$$v^n = \bar{y} - x^n \implies p(\bar{y}|x^n) = p_v(\bar{y} - x^n) \quad (5)$$

The framework operates in two distinct stages: offline model training and online posterior inference.

### 2.1. Offline Noise Characterization

During the offline stage, the system characterizes the noise by computing the arithmetic mean of a training observation set. Individual deviation vectors are generated by calculating the difference between this mean and each respective sample. A VAE is subsequently trained exclusively on these noise vectors,  $v^k = \bar{y}_{\text{train}} - y^k$ .

The VAE architecture consists of an encoder,  $q_\phi(z|v)$ , that maps the high-dimensional noise into a lower-dimensional latent space ( $z \in Z$ ), and a stochastic decoder,  $p_\theta(v|z)$ , that attempts to reconstruct the original input. During training, the network maximizes the Evidence Lower Bound (ELBO), which balances reconstruction accuracy against a Kullback-Leibler (KL) divergence penalty. This regularization penalty ensures the latent space remains smoothly structured and prevents the network from memorizing isolated data points.




Fig. 1: Fused dataset involving the 10D Multivariate logistic dataset (First 3 dimensions)

## 2.2. Online Bayesian Inference

For the online inference phase, the deviation of the prior samples from the observation mean, i.e.,  $\bar{y} - x^n$ , is computed for every prior sample. To accurately assess the probability density of these deviations, the framework implements an Importance Weighted Autoencoder (IWAE) (Burda et al.<sup>3)</sup> structure. Standard VAEs only yield a lower bound on the true log-likelihood, which introduces amortization error due to imperfect posterior approximations. The IWAE resolves this by drawing a large number of independent samples (specifically,  $k = 1024$ ) from the encoder's latent space distribution. By calculating the average ( $\mathcal{L}_n(v^n)$ ) of  $k$  number of importance weights

$$w_i = \frac{p_\theta(v^n|z_i)p(z_i)}{q_\phi(z_i|v^n)} \quad (6)$$

across the latent vectors,  $z_1, \dots, z_k \sim q_\phi(z|v^n)$ , the system achieves a substantially tighter bound on the true log-likelihood. Here,  $p(z_i)$  is the standard Gaussian prior. Finally, these refined likelihood estimates are normalized across all prior states to generate the final posterior weights,  $\beta_n$ , as

$$\beta^n = \frac{L_n}{\sum_{j=1}^N L_j} \quad (7)$$

## 3. Numerical Verification

A core limitation of conventional Bayesian integration is the inability to easily formulate likelihoods for non-Gaussian information. To demonstrate the generative framework's capacity to bypass this constraint, a comprehensive experiment was executed utilizing a 10-dimensional multivariate logistic distribution with independence across individual dimensions.

The synthetic data was drawn from two independent 10-dimensional domains, serving as the prior knowledge base and the new observation set, respectively. Following the previously detailed methodology, the VAE was trained directly on the deviation values between the observed samples and their computed mean. To force meaningful compression and feature extraction, the latent space bottleneck of the neural network was restricted to exactly three dimensions.

To establish a semi-analytical benchmark for verifying the VAE-based fusion results, a Kernel Density Estimation (KDE) approach was utilized. However, explicitly evaluating the joint posterior density across a multidimensional grid is computationally prohibitive due to the curse of dimensionality, as the number of evaluation points scales exponentially as  $O(K^D)$ .

To overcome this intractability, we evaluate the marginal distributions of the fused dataset by assuming independence across individual dimensions. This assumption reduces the computational complexity from exponential to linear, scaling at  $O(D \times K)$ , which renders the validation highly tractable even for high-dimensional cases.

For each dimension  $d \in \{1 \dots D\}$ , the procedure extracts the 1D samples from the prior  $X_{:,d}$  and the observation  $Y_{:,d}$ . A Gaussian KDE is fitted to the prior samples to obtain  $KDE_{prior}$ , and another Gaussian KDE is fitted to the deviation samples ( $\bar{y} - y$ ) to represent the likelihood,  $KDE_{source}$ .

After defining a 1D evaluation grid, the unnormalized posterior density for the  $d$ -th dimension is computed via the element-wise multiplication of the prior density and the likelihood density evaluated at shifted grid arguments

$$p_{unnorm} = KDE_{prior}(grid) \times KDE_{source}(\mu_y - grid) \quad (8)$$

Finally, the true marginal posterior  $p_{post}$  is obtained by normalizing  $p_{unnorm}$  using Simpson's rule for numerical integration over the 1D grid.

As shown in Fig. 1, the proposed generative ML framework proved highly successful at integrating the non-Gaussian datasets. Despite the mathematical complexities inherent in the 10-dimensional logistic case, the VAE effectively operated as a flexible surrogate for the likelihood function. The system generated marginalized posterior distributions that successfully captured the complex data structure without relying on explicit parametric equations, empirically validating the proposed methodology.

## 4. Concluding Remarks

In this study, we present a robust generative methodology based on heteroscedastic VAEs for static data fusion, particularly for non-Gaussian datasets. Furthermore, the inclusion of multi-sample importance weighting via the IWAE objective significantly diminishes amortization errors. The proposed methodology is verified through a case study involving non-Gaussian datasets that demonstrating strong alignment with expected semi-analytical solutions. Notably, this high fidelity is achieved despite the fusion occurring within a compressed latent space equivalent to 30% of the original feature dimensionality. This framework represents a promising direction for robust Bayesian inference in complex, real-world scenarios.

## References

- 1) Cheng, S., Quilodr  n-Casas, C., Ouala, S., Farchi, A., Liu, C., Tandeo, P., Fablet, R., Lucor, D., Iooss, B., Brajard, J., Xiao, D., Janjic, T., Ding, W., Guo, Y., Carrassi, A., Bocquet, M., & Arcucci, R.: Machine Learning With Data Assimilation and Uncertainty Quantification for Dynamical Systems: A Review, IEEE/CAA Journal of Automatica Sinica, 10(6), 1361 – 1387, 2023.
- 2) Kingma, D. P., & Welling, M.: Auto-encoding variational bayes, In Proceedings of the 2nd International Conference on Learning Representations (ICLR), 2014.
- 3) Yuri B., Roger G., and Ruslan S.: Importance weighted autoencoders, In 4th International Conference on Learning Representations (ICLR), 2016.