

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¹ (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¹、中瀬 仁¹、松田 景吾²、杉山 徹²、栗原 祐也³、亀田 敏弘³、清野 友規⁴ (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¹、Sukulthanasorn Naruethep¹、野村 怜佳¹、郭 佳²、大野 晋¹、野島 和也³、森 篤史³、佐藤 誠一³、櫻庭 雅明³、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¹、本田 利器¹ (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¹⁾。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-COM3²⁾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¹⁾。

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)²⁾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

ロト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⁴⁾, 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) ¹⁾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 ²⁾。

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)⁽²⁾ 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)⁽²⁾. The Stochastic Green's Function method is an extension of the empirical Green's Function approach, introduced by Irikura⁽¹⁾, 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)⁽³⁾. 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⁽⁴⁾:

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

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⁽⁵⁾:

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

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

To support city-scale updating, we model the IM–EDP relation in log space with a Bayesian hierarchical regression⁶⁾:

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

Buildings of the same structural type share information through type-level priors on (α_j, β_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 (η, β) 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:

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

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.¹⁾). 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.¹⁾ 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 Welling²⁾), 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 β^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.³⁾ 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, β_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.