

# 計算工学講演会論文集

## オイラー型構造解析の時系列データを用いた3D形状生成 モデル

3D shape generation model using time series data from Eulerian Structural Analysis

仲谷 幸一郎<sup>1)</sup>, 西口 浩司<sup>2)</sup>, 戸井田 一聖<sup>3)</sup>, 千葉 直也<sup>4)</sup>, 加藤 準治<sup>5)</sup>  
Koichiro Nakaya, Koji Nishiguchi, Issei Toida, Naoya Chiba and Junji Kato

<sup>1)</sup>名古屋大学 大学院工学研究科 (〒 464-8603 名古屋市千種区不老町, E-mail: cn.68v.1900@s.thers.ac.jp)

<sup>2)</sup>博(工)名古屋大学大学院工学研究科土木工学専攻准教授,

理化学研究所 計算科学研究センター AI for Science プラットフォーム部門

AI 学習最適化基盤開発ユニット 上級研究員 (〒 103-0027 東京都中央区日本橋 1-4-1 日本橋一丁目三井ビルディング 15 階, E-mail: nishiguchi.koji.r9@f.mail.nagoya-u.ac.jp)

<sup>3)</sup>名古屋大学 大学院工学研究科 (〒 464-8603 名古屋市千種区不老町, E-mail: tuida.issei.s6@s.mail.nagoya-u.ac.jp)

<sup>4)</sup>大阪大学 D3 センター (〒 565-0871 大阪府吹田市山田丘 1-1, E-mail: chiba@nchiba.net)

<sup>5)</sup>Dr.-Ing. 名古屋大学大学院工学研究科土木工学専攻教授 (〒 464-8603 名古屋市千種区不老町, E-mail: kato.junji.i5@f.mail.nagoya-u.ac.jp)

I propose a novel framework that integrates Eulerian structural analysis with DeepSDF to generate 3D shapes informed by mechanical constraints. The Eulerian method efficiently captures time-series data of nonlinear behaviors such as buckling, using fixed Cartesian meshes for stable and scalable parallel computation. DeepSDF encodes shape geometry in a continuous latent space, allowing for precise and flexible geometric representation. This integration connects physical performance with shape generation, enabling iterative refinement of shapes guided by structural analysis results.

**Key Words :** Eulerian method, Elastoplastic analysis, 3D generative Model

### 1. 緒言

近年、深層学習技術の進展により、3次元形状生成モデルは工業設計、医療、建築など様々な分野で注目を集めている。特に、DeepSDF (Signed Distance Function) をはじめとする潜在空間に基づく手法は、滑らかかつ複雑な形状の生成を可能にし、形状表現の自由度を大きく向上させている [5][6]。

一方、これらの生成モデルの多くは形状の幾何学的特徴に着目しており、力学的特性、特に座屈や大変形といった非線形力学現象を十分に考慮することは難しいとされている。設計対象が力学的制約を伴う構造物である場合、その形状が持つ応力・変形挙動を正確に把握し、設計段階で反映することが極めて重要である。

これに対し、構造解析に基づくアプローチを形状生成に統合する試みが進められているが、多くはラグランジュ的枠組みに依存しており、大規模変形や計算効率の観点で課題が残る。このような背景のもと、本研究では、固定格子上で構造挙動を解析するオイラー型解法に注目する。オイラー型解法は、大規模並列計算に適した手法として知られており、従来から流体解析や構造解析への応用が進んでいる。近年では、スーパー・コンピュータ「富岳」を用いた大規模構造解析への適用実績も報告されている [4]。

本研究では、オイラー型構造解析と DeepSDF を組み

合わせることで、非線形挙動を形状生成に取り込むためのフレームワークを検討する。従来はオイラー法による速度場やひずみ場などの時系列データを活用することが想定されていたが、今回の初期的試みとしては、押し込み量(変位量)に応じた衝撃吸収エネルギー(absorption energy)の時系列データを用いるアプローチを採用している。これにより、大変形の一例としての「押し込みによるエネルギー衝撃吸収特性」を設計段階から取り込む可能性を探る。

### 2. 背景と従来手法

#### (1) DeepSDF による形状生成の原理

DeepSDF は、符号付き距離関数 (SDF) を表現するためにトレーニングされたデコーダ型ニューラルネットワークであり、潜在ベクトルを入力することで連続的な3次元形状を生成できる手法である [5][6]。具体的には、SDF を以下のように定義する：

$$\text{SDF}(\mathbf{x}) = s : \mathbf{x} \in \mathbb{R}^3, s \in \mathbb{R}. \quad (1)$$

ここで、与えられた空間点  $\mathbf{x}$  が最も近い表面までの距離を連続関数として出力し、その値の符号によって物体の内側(負)か外側(正)かをエンコードする。 $\text{SDF}(\cdot) = 0$  となる等価面が物体の表面を定義し、実際のメッシュはマーチングキューブ法などを用いて描画可能である。

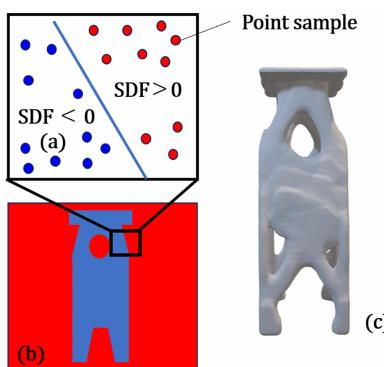


図-1 DeepSDF の原理: SDF=0 となる暗黙曲面の定義と再構成された 3D 形状

図 2 に示すように、学習は形状表面の内外にサンプル点を取り、それらの位置と SDF 値のペアから構成されたデータセットをもとに、ネットワークを訓練することで行われる。潜在ベクトルによって形状の情報を圧縮し、ネットワークの追加入力として与えることで、多様な形状を単一のモデルで表現可能とする。

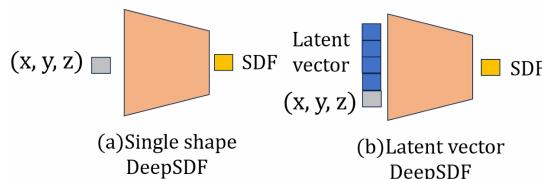


図-2 (a) 単一形状の DeepSDF, (b) 潜在ベクトルを導入した多形状対応の DeepSDF

このように深層ニューラルネットワークを用いてポイントサンプルから直接連続的な SDF を回帰できるため、学習後のネットワークはあらゆるクエリ位置  $x$  の SDF 値を予測し、そこからゼロレベルセットの表面を抽出できるのが特徴である。さらに、潜在変数を導入することで、多様な形状を一つのニューラルネットワークに内包し、形状生成や補間を行う際に柔軟性を得られる。しかし、外力や変形速度などの動的・非線形挙動を表す力学情報をどのように統合するかについては、従来の研究でも課題となっている。

## (2) オイラー型構造解析およびトポロジー最適化に基づく形状生成

従来、構造解析にはラグランジュ的手法が多く用いられてきたが、大変形問題では格子の歪みや数値的不安定性が生じやすい。これに対し、オイラー型構造解析では空間格子を固定したまま物質の運動や変形を記述するため、格子の歪みを避けながら解析が可能であり、非線形変形や座屈の再現に有効である。ただし、解析結果として得られるデータ（例：速度場、ひずみ分布など）を機械学習モデルにどのように結びつけるかが実務上のボトルネックとなりうる。

今回のアプローチでは、速度場・ひずみ場の空間分布を直接取り込む代わりに、初期段階として押し込み量別

に計算した衝撃吸収エネルギーを主たる指標として用い、複数段階にわたる変形挙動を「時系列データ」として整理する。これにより、力学的な制約をシンプルかつ明確に DeepSDF へ与えられる点を狙いとしている。

本研究では、トポロジー最適化を用いて設計自由度の高いクラッシュボックス形状を生成し、それを対象にオイラー型解析を行う。トポロジー最適化とは、所与の設計空間内で、剛性やエネルギー衝撃吸収といった力学的性能を最大化／最小化するように材料の配置を最適化する手法である。解析領域は図 3 と図 4 の通りである。

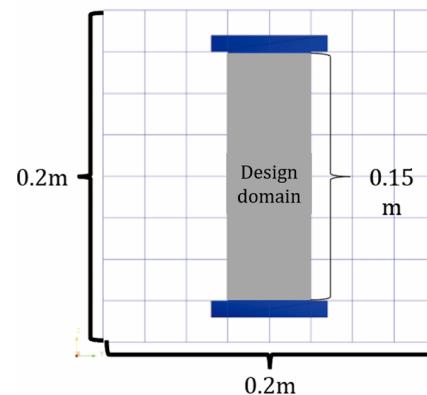


図-3 線形トポロジー最適化における計算領域

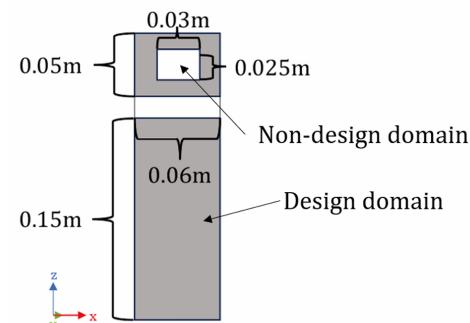


図-4 線形トポロジー最適化における設計領域・非設計領域

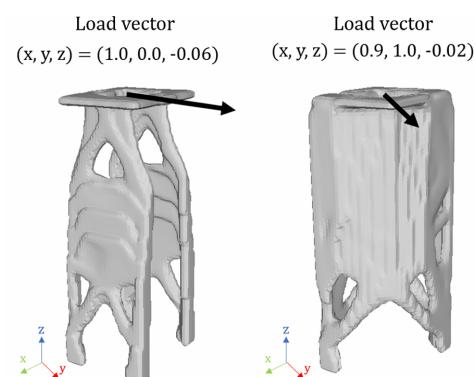


図-5 トポロジー最適化により得られたクラッシュボックス形状の一例

図5に示すように、荷重条件の違いに応じて最適化された形状は大きく異なり、設計の初期段階から形状の構造的性能を制御するために有効である。

クラッシュボックスの材料特性には、アルミニウム材料(ヤング率:70GPa, ポアソン比:0.3, 密度:2.7g/cm<sup>3</sup>)を採用している。材料モデルとしては線形弾性体を仮定し、トポロジー最適化では体積分率5%, 最小セルサイズ1.5mmの条件で計算を行っている。

**表-1 Condition of topology optimization**

Material :	Aluminum
Density :	2.7g/cm <sup>3</sup>
Young's modulus :	70GPa
Poisson's ratio :	0.3
Material model :	Linear elastic material
Volume fraction :	5%
Minimum cell size :	1.5mm
Number of cells :	1,048,576
Number of nodes :	8
Optimal number of steps :	50
Computational time :	1200s
Number of datasets :	21,998
Number of training data :	20,000
Number of test data :	1998

次節では、こうして得られた形状を用いて押し込み試験を模擬し、その力学的応答をDeepSDFに統合する提案手法の詳細を述べる。

### 3. 提案手法の概要

本研究のフレームワークは、以下の要点で構成される。

#### (1) オイラー型構造解析による押し込み実験のシミュレーション

本研究では、トポロジー最適化によって得られたクラッシュボックス形状を用いて、押し込み試験を模擬したオイラー型構造解析を実施する。押し込み量を段階的に増加させながら各ステップでの衝撃吸収エネルギーを算出し、それを時系列データとして取得する。オイラー法を用いることで、大変形が生じた際にも計算格子の歪みを回避し、安定した解析を行うことができる。

#### (2) DeepSDFとの連携

得られた押し込み量別の衝撃吸収エネルギーの変化を、形状の力学的指標としてDeepSDFモデルに統合する。具体的には、潜在ベクトルと形状のSDF(Signed Distance Function)に対して「特定の押し込み量で衝撃吸収エネルギーが所定の値をとる」といった制約を与えることで、構造応答を反映した形状生成を行う。現在は初期段階の試みであり、衝撃吸収エネルギーの目標範囲や、特定の変形モードに対する制約条件を含めたモデル拡張の可能性についても検討している。

#### (3) 生成形状の力学的評価

まず、生成について説明する。生成とは、未知の力学的パラメータを与えたときに、指定した性能を満たす形状を出力できるかを検証するプロセスである。再構築との主な違いは、生成ではSDF値から最適化された潜在ベクトルを使うのではなく、正規分布からランダムに取得した潜在ベクトルを用いる点にある。これは、学習済みモデルが獲得した訓練データの特徴が反映された潜在空間から、形状の候補をランダムにサンプリングしていることを意味する。図6

DeepSDFによって生成された形状に対し、再度オイラー型構造解析を実施し、与えられた衝撃吸収エネルギーの目標値との整合性を定量的に検証する。本検証においては、押し込み変位に対する外力の仕事として定義される衝撃吸収エネルギーを評価指標とし、生成形状の力学的応答との一致度を分析する。

加えて、予測結果と目標値との相対誤差が顕著に大きかったケースのうち、衝撃吸収エネルギーが目標を大きく\*\*上回ったケース(Over-absorption)および下回ったケース(Under-absorption)\*\*をそれぞれ10例抽出する。これらのケース群について、生成形状の幾何学的特徴および応力・変形分布を比較・解析する。

この一連の評価を通じて、生成モデルが衝撃吸収性能をどの程度安定的に再現可能か、また性能限界がどのように現れるかを明らかにし、モデルの改善と設計ガイドライン策定に資する知見を得ることを目的とする。

### 4. 結言

本研究では、オイラー型構造解析とDeepSDFを統合した、力学性能を考慮した3次元形状生成フレームワークを提案した。特に、押し込み量に対する衝撃吸収エネルギーを時系列的に捉え、それをDeepSDFに統合することで、大変形を伴う構造挙動を反映した形状生成の可能性を示した。

なお、トポロジー最適化に用いた数値計算手法の詳細や、得られたクラッシュボックス形状に対する構造解析結果などの数値計算例については、講演会当日に紹介する予定である。

### 5. 謝辞

本研究は、HPCIシステム利用研究課題(課題番号:hp240296, 課題代表者:西口浩司)を通じて、理化学研究所が提供するスーパーコンピュータ「富岳」の計算資源の提供を受け、実施した。また、本研究はJSPS科研費24K14968の助成を受けた。

### 参考文献

- [1] Alexey D, Lucas B, Alexander K and Dirk W : Transformers for image recognition at scale, International Conference on Learning Representations, pp.197 – 224, 2021.
- [2] Ashish V and Noam S: Attention is all you need, arXiv:1706.03762, 2017.
- [3] Alex N, Heewoo J, Prafulla D, Pamela M and Mark

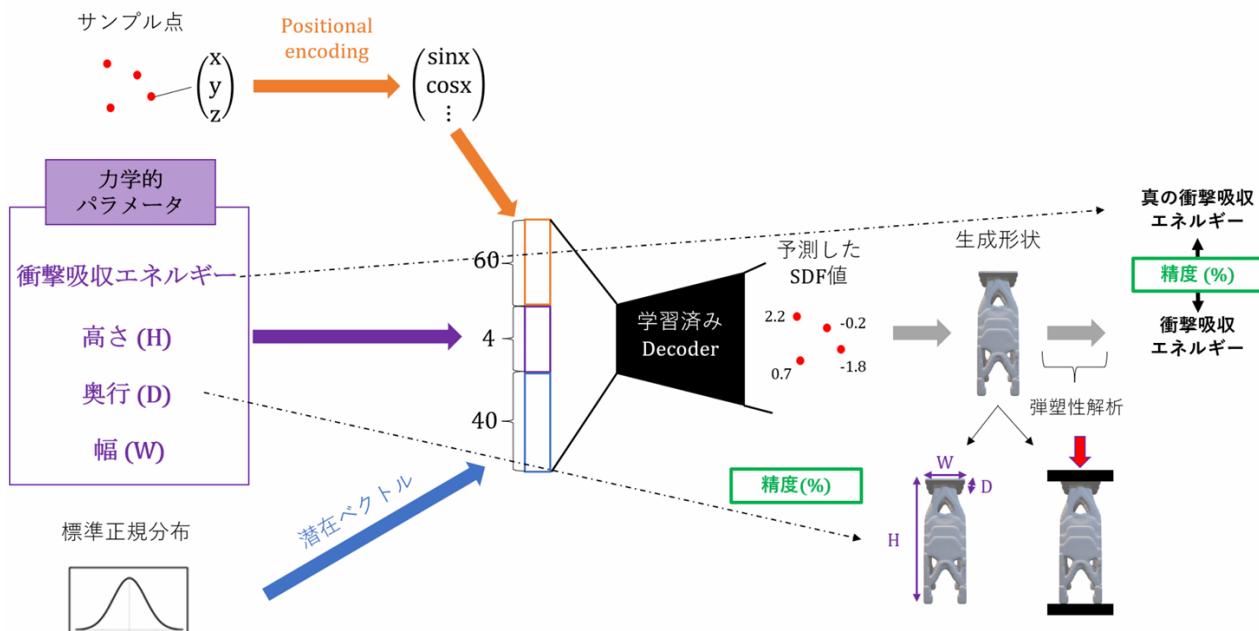


図-6 入力した力学的パラメータによる形状生成とその精度検証の流れ

- C: Point-e: A system for generating 3D point clouds from complex prompts, arXiv:2212.08751, 2022.
- [4] K. Nishiguchi, S. Takeuchi, H. Sugiyama, S. Okazawa, T. Katsuhara, K. Yonehara, S. Kojima, K. Kawahara, H. Hoshiba, and J. Kato: Eulerian elasto-plastic simulation of vehicle structures by building-cube method on supercomputer Fugaku, HPCAsia '24, ACM, pp.145 – 153, 2024.
- [5] Jeong P, Peter F, Julian S, Richard N and Steven L: DeepSDF: Learning Continuous Signed Distance Functions for Shape Representation, CVPR, pp.165 – 174, 2019.
- [6] Lipman H.-T.D., Wang F, Alec Jacobson A. and Fidler S.: DeepSDF: Learning Smooth Neural Functions via Lipschitz Regularization, ACM SIGGRAPH Conference, pp.1 – 13, 2022.
- [7] Heewoo J and Alex N: Shap-e: Generating conditional 3D implicit functions prompts, arXiv:2305.02463, 2023.
- [8] Chen-Hsuan L, Jun G, Luming T, Towaki T, Xiaohui Z, Xun H, Karsten K, Sanja F, Ming-Yu L and Tsung-Yi L: High-Resolution Text-to-3D Content Creation, arXiv:1512.03012, 2015.
- [9] Ben P, Ajay J and Ben M: Dreamfusion: Text-to-3D using 2D diffusion content creation, arXiv:2209.14988, 2022.
- [10] Olga R, Jia D, Hao S et al.: ImageNet Large Scale Visual Recognition Challenge, IJCV, pp.211 – 252, 2015.
- [11] Angle X.C., Thomas F., Leonidas G., Pat H., Qixing H., Zimo L., Silvio S., Manolis S., Shuran S., Hao S., Jianxiong X., Li Y., Fisher Y.: ShapeNet: An Information-Rich 3D Model Repository, arXiv:1512.03012, 2015.
- [12] Alec R, Chris H, Aditya R, Gabriel G, Sandhini A, Girish S, Amanda A, Pamela M, Jack C, Gretchen K and Ilya S: Learning transferable visual models from natural language supervision, arXiv:2103.00020, 2021.
- [13] Bloesch M., Czarnowski J., Clark R., Leutenegger S., Davison A.J.: Codeslam-learning a compact, optimisable representation for dense visual SLAM, arXiv:1804.00874, 2018.
- [14] Bagautdinov T., Wu C., Saragih J., Fua P., Sheikh Y.: Modeling facial geometry using compositional VAEs, CVPR, 2018.
- [15] Litany O., Bronstein A., Bronstein M. and Makadia A.: Deformable shape completion with graph convolutional autoencoders, CVPR, 2017.
- [16] Nakahashi K.: Building-cube method for flow problems with broadband characteristic length, International Conference on Computational Fluid Dynamics, pp.77 – 81, 2022.