

カリキュラム DeepSDF に基づく薄板構造生成モデル

Thin-Plate Structure Generation Model Based on Curriculum DeepSDF

高根澤空来¹⁾ 西口浩司²⁾ 米原圭一³⁾ 小島茂樹⁴⁾ 川原康熙⁵⁾

Sora Takanezawa, Koji Nishiguchi, Keiichi Yonehara, Shigeki Kojima and Kosho Kawahara

¹⁾名古屋大学工学研究科 (〒 464-8601 名古屋市千種区不老町, E-mail: takanezawa.sora.p7@s.mail.nagoya-u.ac.jp)

²⁾博士 (工学) 名古屋大学工学研究科准教授, 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)

³⁾トヨタ自動車株式会社 (〒 471-8572 愛知県豊田市トヨタ町 1 番地, E-mail: keiichi_yonehara@mail.toyota.co.jp)

⁴⁾トヨタ自動車株式会社 (〒 471-8572 愛知県豊田市トヨタ町 1 番地, E-mail: shigeki_kojima@mail.toyota.co.jp)

⁵⁾トヨタ自動車株式会社 (〒 471-8572 愛知県豊田市トヨタ町 1 番地, E-mail: kosho_kawahara@mail.toyota.co.jp)

This study introduces a deep generative model for thin-plate structures, which integrates local geometric feature extraction and curriculum learning. The model leverages DeepSDF, a decoder-based neural network, to implicitly represent shapes via signed distance functions (SDFs). To improve shape reconstruction accuracy, we enhance DeepSDF by incorporating point cloud feature extraction for adaptive weighting. Furthermore, a curriculum learning strategy is employed to facilitate progressive network training. The experimental results demonstrate that the proposed model achieves enhanced shape reconstruction fidelity. This model and its associated methodology contribute to advancements in thin-plate structure modeling using deep learning techniques.

Key Words : 3D Generative model, Thin-Plate Structure, DeepSDF

1. はじめに

近年、深層学習技術の発展に伴い、3次元形状の生成や再構築に関する研究が活発化している。特に、符号付き距離関数 (SDF) を用いた形状表現は、複雑なトポロジーや微細な形状を効率的に扱うことができるため、注目を集めている。薄板構造は、自動車や航空機の部品など、様々な産業分野で広く利用されており、その形状設計は製品の性能や安全性に大きく影響を与える。しかし、従来の形状生成手法では、薄板構造特有の微細な凹凸形状や薄肉部を十分に表現することが困難であり、高精度な形状生成が求められている。そこで本研究では、DeepSDF を基盤とし、点群特徴抽出に基づく凹凸部を重視した重み付けと、Curriculum DeepSDF のネットワーク構成を活用することで、薄板構造の表現能力を向上させることを目的とする。本研究では、再構築タスクにおける既存モデルとの比較による汎化性能の評価を行う。

2. 薄板構造の生成モデル

(1) DeepSDF

本研究では、3次元形状の連続表現手法として DeepSDF を採用した。DeepSDF は符号付き距離関数 (SDF) に基づき、滑らかな形状表現を可能にする。

DeepSDF は、空間中の点 x に対し、物体表面までの距離に正負の符号を付与した SDF 値 $F(x)$ を定義する。物体内部では SDF 値は負、外部では正となり、 $F(x) = 0$ が物体表面を表す。この連続表現により、高解像度と省メモリを両立し、Marching Cubes 法によりポリゴン

メッシュを生成できる。深層ニューラルネットワーク f_θ は空間座標 x と潜在ベクトル z を入力とし、SDF 値を予測する。潜在ベクトル z は形状の特徴を捉えた低次元表現であり、学習を通じて標準多変量正規分布に近づくよう正則化される。

(2) Curriculum DeepSDF の導入

本研究では、学習が局所最適解に陥るリスクを低減し、形状の精緻な再現を可能にするために Curriculum DeepSDF の学習手法を採用し、ネットワークの層数を段階的に変化させる学習スケジュールを構築した。この学習スケジュールは、以下の表 1 に示す通りである。またネットワークについては図 1 に示す通りである。

表-1: Curriculum DeepSDF の学習スケジュール

ステージ	エポック数	使用する層
1	1-200	入力層, 隠れ層 3 層, 出力層
2	201-600	入力層, 隠れ層 4 層, 出力層
3	601-1000	入力層, 隠れ層 5 層, 出力層
4	1001-2000	入力層, 隠れ層 6 層, 出力層

3. 条件付き生成モデルとネットワーク構造の改良

本研究では、薄板構造の表現能力不足を克服するため、Curriculum DeepSDF を基盤に、局所構造への重み付けを施した損失関数の再定義を行った。

薄板構造や薄肉部では、表面近傍の微細な凹凸形状




図-1: Curriculum DeepSDF のネットワーク構造

が力学的特性を決定する上で重要である．そこで，局所的な幾何学的特徴を効率的に捉えるために，主成分分析（PCA）を用いる．具体的には，局所点群 $\mathcal{P} = \{p_i\}_{i=1}^n \subset \mathbb{R}^3$ に対して PCA を適用し，共分散行列 C の固有値 $\lambda_1 \geq \lambda_2 \geq \lambda_3 \geq 0$ と固有ベクトル v_1, v_2, v_3 を取得する．次に，各点 p_i の局所的な次元性を示す指標 α_i を以下の式で定義する．

$$\alpha_i = \operatorname{argmax}(\lambda_1 - \lambda_2, \lambda_2 - \lambda_3, \lambda_3).$$

この指標を用いて，サンプル点 p_i に対する重み ω_i を以下の式で定義する．

$$\omega_i = \begin{cases} \frac{\tilde{\alpha}_{k(i)}}{(\|p_i - p_{k(i)}\|_2 + 1)^{1.5}} & \text{if } \frac{\tilde{\alpha}_{k(i)}}{(\|p_i - p_{k(i)}\|_2 + 1)^{1.5}} \geq \theta, \\ \theta & \text{otherwise.} \end{cases}$$

この重みは，表面近傍の凹凸部や薄肉部において大きな値を取るよう設計する．そして，重み付けを導入した損失関数 L_{prop} を以下の式で定義し，局所的な幾何学的特徴の再現性を優先的に向上させる．

$$L_{\text{prop}} = \frac{1}{\sum_{i=1}^N \omega_i} \sum_{i=1}^N \omega_i \cdot |\text{SDF}_{\text{gt}}(p_i) - \text{SDF}_{\text{pred}}(p_i)| + \lambda_{\text{reg}} L_{\text{reg}},$$

ここで：

- $\text{SDF}_{\text{gt}}(p_i)$: 点 p_i の真の SDF 値．
- $\text{SDF}_{\text{pred}}(p_i)$: 予測された SDF 値．
- λ_{reg} : 正則化項 L_{reg} の重み．

4. 訓練結果とその検証

本章では，提案する深層学習モデルの有効性を検証するため，データセットの詳細，再構築タスクの結果について説明する．

(1) データセット

本研究で再構築タスクに用いたデータセットは，断面形状，表面形状，および寸法が異なる薄板構造 20 個から構成される（図 2）．

(2) 再構築タスクの汎化性能検証

再構築精度を Chamfer-L1 Distance（式 1）を用いて評価した．提案モデルの Chamfer Distance は 5.44×10^{-6} ，比較対象モデルは 1.41×10^{-4} であり，提案モデルの再構築精度が向上した．図 3 に示すように，提案モデルは薄板構造の縁辺部や表面の凹凸をより忠実に再現した．





図-2: 再構築タスク用データセットの形状

$$\text{CD}(X, Y) = \frac{1}{|X|} \sum_{x \in X} \min_{y \in Y} \|x - y\| + \frac{1}{|Y|} \sum_{y \in Y} \min_{x \in X} \|x - y\| \quad (1)$$



(a) 提案手法を用いて再構築した形状 (b) 既存のモデルを用いて再構築した形状 (c) 正解形状

図-3: 再構築形状と正解形状

5. 結言

本研究では，深層学習モデル DeepSDF の薄板構造に対する表現能力向上を目的とし，点群の局所特徴に基づく適応的な重み付けと，学習過程を段階的に調整する Curriculum DeepSDF のネットワーク構造を導入し，Chamfer Distance による評価において，提案モデルが既存モデルと比較して薄板構造の再構築精度において優位性を示すことを確認した．

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] Jeong P, Peter F, Julian S, Richard N and Steven L : DeepSDF: Learning Continuous Signed Distance Functions for Shape Representation, *arXiv:1901.05103*(2022).

- [2] P. Bojanowski, A. Joulin, D. Lopez-Pas, and A. Szlam. Optimizing the latent space of generative networks. In J. Dy and A. Krause, editors, *Proceedings of the 35th International Conference on Machine Learning, volume 80 of Proceedings of Machine Learning Research*, pages 600–609. PMLR, 10–15 Jul 2018.
- [3] Ashish V and Noam S: Attention is all you need, *arXiv:1706.03762*, 2017.
- [4] Ben M., Pratul P. Srinivasan, Matthew T., Jonathan T. Barron, Ravi R. and Ren N. : NeRF: representing scenes as neural radiance fields for view synthesis, *ACM*, pp.99-106, 2021.
- [5] Matthew T., Pratul P. Srinivasan, Ben M., Sara F., Nithin., Utkarsh S., Ravi R., Jonathan T. Barron and Ren N. : Fourier features let networks learn high frequency functions in low dimensional domains, *Curran Associates*, pp.11-20, 2020.
- [6] William E. Lorensen and Harvey E.Cline : Marching cubes: A high resolution 3d surface construction algorithm, *ACM SIGGRAPH Computer Graphics*, pp.163-169, 1987.
- [7] 戸井田 一聖, 西口 浩司, 千葉 直也, 和田 有司, 横田 理央, 干場 大也, 加藤 準治 (2024) : 構造力学を考慮した3次元形状深層生成モデルの提案, 日本計算工学会論文集, Vol.2024, pp.20241010
- [8] Duan,Y. Zhu,H. Wang,H. Yi,L. Nevatia,R. Guibas,L.J. (2020): Curriculum deepsdf, *European Conference on Computer Vision*, pp.51–67
- [9] Jerome Demantké, Clément Mallet, Nicolas David, Bruno Vallet, Dimensionality based Scale Selection in 3D Lidar Point Clouds, *ISPRS International Archives of the Photogrammetry, Remote Sensing and Spatial Information Sciences*, XXXVIII-5/WG12, 97-102 (2011)
- [10] Kingma,D.P. Ba,J. (2014): Adam: A method for stochastic optimization, *ICLR* 2014.
- [11] Li, S., Zhao, H., Varma, M., Salpekar, S., Noordhuis, P., Li, F., Paszke, A., Chintala, S. and Smola, A. (2020): PyTorch Distributed: Experiences on Accelerating Data Parallel Training. *VLDB*, pp.308-323.