

構造力学を考慮した DeepSDF に基づく 3次元形状生成モデル

3D Shape Generative Model based on DeepSDF incorporating Structural Mechanics

戸井田一聖¹⁾ 千葉直也²⁾ 西口浩司³⁾ 和田有司⁴⁾ 横田理央⁵⁾ 干場大也⁶⁾ 加藤準治⁷⁾
Issei Toida, Naoya Chiba, Koji Nishiguchi, Yuji Wada, Rio Yokota, Hiroya Hoshiba and Junji Kato

¹⁾名古屋大学大学院工学研究科土木工学専攻 (〒 464-8603 名古屋市千種区不老町,E-mail: ozaki.yuri.a0@s.mail.nagoya-u.ac.jp)

²⁾東北大学大学院情報科学研究科 助教 (〒 464-8603 名古屋市千種区不老町,E-mail: chiba@nchiba.net)

³⁾名古屋大学大学院工学研究科土木工学専攻 准教授 (〒 464-8603 名古屋市千種区不老町,E-mail: kojinishiguchi@civil.nagoya-u.ac.jp)

⁴⁾東京工業大学未来産業技術研究所 助教 (〒 464-8603 名古屋市千種区不老町,E-mail: ywada@sonic.pi.titech.ac.jp)

⁵⁾東京工業大学学術国際情報センター 教授 (〒 464-8603 名古屋市千種区不老町,E-mail: riroyokota@gsic.titech.ac.jp)

⁶⁾名古屋大学大学院工学研究科土木工学専攻 助教 (〒 464-8603 名古屋市千種区不老町,E-mail: hiroyahoshiba@nagoya-u.jp)

⁷⁾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: junjikato@civil.nagoya-u.ac.jp)

We propose a deep generative model for 3D shapes that incorporates structural mechanics parameters and utilize a dataset of 6,667 shapes created by topology optimization. Our model is based on DeepSDF, a decoder-type neural network that implicitly represents shapes as signed distance functions (SDFs). We extend DeepSDF to condition the shape generation on structural mechanics parameters such as strain energy, load direction, volume, and dimension. Additionally, we introduce positional encoding to enhance spatial resolution. Our dataset comprises various 3D shapes generated by a linear topology optimization method using the building-cube method. We use strain energy, quantified through Eulerian elastoplastic analysis, as a quantitative indicator of shape structural performance. We train our model on the dataset and evaluate its ability to generate 3D shapes. The results demonstrate that our model can produce 3D shapes with high fidelity and diversity, achieving an accuracy of 93.1% for shapes generated based on mechanical parameters. Our model and dataset open up new possibilities for 3D shape generation and structural design using deep learning.

Key Words : 3D Generative model, Structural mechanics, DeepSDF, Topology optimization, Capacity Computing

1. はじめに

近年, StableDiffusion[1] のような画像生成 AI だけでなく, Transformer[2] ベースの拡散モデルを用いた Point-E[3], Shape-E[4], DreamFusion[5] などの 3 次元形状深層生成モデル (text-to-3D model) が続々と提案されている. これらの生成モデルの訓練には WebImage Text, ImageNet などの 2 次元画像データセットが用いられている. ただし, これらのデータセットはコンピュータグラフィックスやコンピュータビジョンの研究を想定したものであり, CLIP (Contrastive Language-Image Pre-Training) 特徴量 [6] による言語と画像の間のマッピングが利用可能であることに大きく依存している. この CLIP 特徴量は対照学習と呼ばれる技術と大規模な画像・テキストのデータセットを用いて事前学習されたモデルで, 近年の言語指示を用いた画像生成モデルの重要な要素技術となっている. このため, 構造力学の情報のような, 既存の大規模データセットやマルチモーダルなデータセットが存在しない場合への応用は難しく, 構造力学的情報を有するデータセットおよび構造力学的情報を考慮した 3 次元生成モデルは提案されていない. この場合の 3 次元形状生成モデルは入力として構

造力学的パラメータを指定し, そのパラメータを満たす 3 次元形状を生成する parameter-to-3D model を意味する.

以上の背景から本研究では, 構造力学のパラメータを含む 3 次元形状データセットを作成し, 構造力学のパラメータを考慮した 3 次元形状確率的生成モデルを提案する. 3 次元形状データセットについて, 形状は Building-Cube 法 [7] に基づく線形トポロジー最適化 [8] により作成し, その形状に付随した構造力学のパラメータはビルディングキューブ法を用いたオイラー型構造-流体統一解法で弾塑性衝突解析を行うことで求める. 3 次元形状深層生成モデルは形状を深層ニューラルネットワークで陰的に表現する DeepSDF[10] を基礎とした深層生成モデルを用いる.

2. DeepSDF による物体形状の陰的表現

(1) オートデコーダ型の DeepSDF の定式化

オートデコーダに基づく形状符号化 DeepSDF の定式化にあたって, オリジナルの DeepSDF でも用いられた潜在ベクトルに関する正則化を行う. これは確率モデ

ルとしての DeepSDF のデコーダーの解釈から、潜在ベクトルが平均値 0 の多変量ガウス分布に近づくことが示されている [10]. N 個の形状からなるデータセットがあり、それぞれが符号付距離関数 SDF^i で表わされるとする. K 個のサンプル点とそれらの符号付き距離値を用意する.

$$X_i = \{(\mathbf{x}_j, s_j) : s_j = SDF^i(\mathbf{x}_j)\} \quad (1)$$

オートデコーダの場合、エンコーダがないため各潜在ベクトル \mathbf{z}_i はトレーニング形状 X_i とペアになる. 形状の SDF サンプルの集合 X_i に対する潜在ベクトル \mathbf{z}_i の事後確率は次のように分解される.

$$p_\theta(\mathbf{z}_i | X_i) = p(\mathbf{z}_i) \prod_{(\mathbf{x}_j, s_j) \in X_i} p_\theta(s_j | \mathbf{z}_i; \mathbf{x}_j) \quad (2)$$

ここで θ は SDF の尤度をパラメータ化している. 潜在ベクトル空間では、潜在ベクトルの事前分布 $p(\mathbf{z}_i)$ を平均値 0 の多変量ガウス分布であると仮定し、球状の共分散 $\sigma^2 I$ を持つものとする. この事後分布は、理想的には潜在ベクトルが偏りなく性質の良い分布に従うべきであるというアイデアに基づいており、経験的に良い解に収束するのに必要だと示されており [10] 本研究でもそれを採用した. オートデコーダに基づく DeepSDF の定式化では SDF の尤度を深層 FFNN を介して表現し、一般性を損なわない範囲で尤度が次の形式を取ると仮定する.

$$p_\theta(s_j | \mathbf{z}_i; \mathbf{x}_j) = \exp(-\mathcal{L}(f_\theta(\mathbf{z}_i, \mathbf{x}_j), s_j)) \quad (3)$$

SDF の予測値 $\tilde{s}_j = f_\theta(\mathbf{z}_i, \mathbf{x}_j)$ はネットワークを使用して表現される. $\mathcal{L}(\tilde{s}_j, s_j)$ はネットワークの予測と実際の SDF 値 s_j を近づけるための損失関数であり、本論文では SDF 値にガウス分布を仮定する損失関数を用いている. 訓練時には個々の潜在ベクトル $\{\mathbf{z}_i\}_{i=1}^N$ 及びネットワークのパラメータ θ に関して、すべての訓練形状にわたる共通の事後対数確率を最大化する. 上記より、本研究における損失関数は以下の式 (4) で表わされる. なお第一項は SDF 値の損失、第二項は潜在ベクトルの分布に関する損失である.

$$\arg \min_{\theta, \{\mathbf{z}_i\}_{i=1}^N} \sum_{i=1}^N \left(\sum_{j=1}^K \mathcal{L}(f_\theta(\mathbf{z}_i, \mathbf{x}_j), s_j) + \frac{1}{\sigma^2} \|\mathbf{z}_i\|_2^2 \right) \quad (4)$$

推論時には、訓練後に θ を固定し、形状 X_i に対する形状コード L_i は最大事後確率推定 (Maximum A Posteriori; MAP 推定) を用いて次のように表される.

$$\hat{\mathbf{z}} = \arg \min_{\mathbf{z}} \sum_{(\mathbf{x}_j, s_j) \in X} \mathcal{L}(f_\theta(\mathbf{z}, \mathbf{x}_j), s_j) + \frac{1}{\sigma^2} \|\mathbf{z}\|_2^2 \quad (5)$$

この定式化は任意のサイズと分布の SDF サンプル点に対して有効であり、損失に関する \mathbf{z} の勾配は各 SDF サンプル点に対して個別に計算することができる. これにより、DeepSDF は深度マップなどの部分的な観測の形状を処理できる.

3. オイラー型弾塑性解析における構成方程式

連続体の運動方程式において、Cauchy 応力テンソルについて関係式を与えなければ方程式系は閉じないため、物質の運動について方程式を解くことはできない. 方程式系が閉じ、物質の運動について方程式を解くことができるようにするためには、Cauchy 応力テンソル (物質の応力) とひずみテンソル (物質の変形) を結びつける構成方程式を導入することが必要となる. 本節では、本研究における固体と流体の構成方程式を示す.

(1) 固体の構成方程式

本研究では、線形等方硬化を伴う von-Mises 型の降伏関数を用いた弾塑性構成則を採用する.

$$f = \sqrt{\frac{3}{2} (\boldsymbol{\sigma}' : \boldsymbol{\sigma}') - \bar{\sigma}_y} \quad (6)$$

$$\bar{\sigma}_y = \bar{\sigma}_y^0 + H \bar{\varepsilon}_p \quad (7)$$

$$l_p = \dot{\gamma} \frac{\partial f(\boldsymbol{\sigma}, \boldsymbol{\varepsilon}_p)}{\partial \boldsymbol{\sigma}} \quad (8)$$

ここで、 $\boldsymbol{\sigma}'$ は Cauchy 応力の偏差成分、 $\bar{\sigma}_y$ は降伏応力、 $\bar{\sigma}_y^0$ は初期降伏応力、 H は硬化係数、 $\bar{\varepsilon}_p$ は相当塑性ひずみ、 $\dot{\gamma}$ は塑性乗数である. 式 (6) の Mises の降伏関数が 0 以下であれば弾性変形範囲、0 より大きい値であれば塑性変形範囲となる. 塑性変形に伴う降伏応力 $\bar{\sigma}_y$ の変化を、式 (7) の線形等方硬化則によって追跡し、相当塑性ひずみ増分を式 (8) の塑性流れ則より求めることで、塑性変形範囲における固体の変形を表現する.

弾性変形については、Hencky の超弾性モデルを用いて定式化を行う.

$$\Psi = \mu [(\ln \lambda_{e,1})^2 + (\ln \lambda_{e,2})^2 + (\ln \lambda_{e,3})^2] + \frac{\lambda}{2} (\ln J)^2 \quad (9)$$

ここで、 Ψ は Hencky 超弾性体のひずみエネルギー密度関数、 μ はラメの第 2 定数、 $\lambda_{e,\alpha}$ ($\alpha = 1, 2, 3$) は各方向の主方向弾性ストレッチ、 λ はラメの第一定数、 J は体積変化率である. 主方向弾性ストレッチ $\lambda_{e,\alpha}$ を求めるため、変形勾配テンソル \mathbf{F} を以下のように弾性成分 \mathbf{F}_e と塑性成分 \mathbf{F}_p に乗算分解する.

$$\mathbf{F} = \mathbf{F}_e \mathbf{F}_p \quad (10)$$

また、塑性右 Cauchy-Green 変形テンソル \mathbf{C}_p 、弾性左 Cauchy-Green 変形テンソル \mathbf{B}_e はそれぞれ以下のようになる.

$$\mathbf{C}_p = \mathbf{F}_p^T \mathbf{F}_p \quad (11)$$

$$\mathbf{B}_e = \mathbf{F}_e \mathbf{F}_e^T \quad (12)$$

なお、弾性左 Cauchy-Green 変形テンソル \mathbf{B}_e は塑性右 Cauchy-Green 変形テンソル \mathbf{C}_p を用いて以下のように表すことができる.

$$\mathbf{B}_e = \mathbf{F} \mathbf{C}_p^{-1} \mathbf{F}^T \quad (13)$$

ここで、弾性左 Cauchy-Green 変形テンソル \mathbf{B}_e を用いることで、主方向弾性ストレッチ $\lambda_{e,\alpha}$ を以下の式で求めることができる。

$$\mathbf{B}_e = \sum_{\alpha=1}^3 \lambda_{e,\alpha}^2 \mathbf{n}_\alpha \otimes \mathbf{n}_\alpha \quad (14)$$

ただし、 \mathbf{n}_α は各主方向の単位ベクトルを表す。

式 (9) において、 J は $\lambda_{e,1}$, $\lambda_{e,2}$, $\lambda_{e,3}$ の積に等しい。この条件を用いることで、Kirchhoff 応力の主方向成分 $\tau_{\alpha\alpha}$ は以下の式で表される。

$$\tau_{\alpha\alpha} = \frac{\partial \Psi}{\partial \ln \lambda_\alpha} = 2\mu \ln \lambda_\alpha + \lambda \ln J \quad (15)$$

Cauchy 応力テンソルは Kirchhoff 応力から体積変化率 J を除することで求められるため、以下の式によって Cauchy 応力テンソルとひずみテンソルを結びつけることができる。

$$\sigma_{\alpha\alpha} = \frac{2\mu}{J} \ln \lambda_\alpha + \frac{\lambda}{J} \ln J \quad (16)$$

さらに、Cauchy 応力を偏差成分と静水圧成分に分解することで、偏差 Cauchy 応力の主方向成分 $\sigma'_{\alpha\alpha}$ を以下の式で導くことができる。

$$\sigma'_{\alpha\alpha} = \frac{2\mu}{J} \ln \lambda_\alpha - \frac{2\mu}{3J} \ln J \quad (17)$$

(2) 流体の構成方程式

本研究では流体の構成方程式として、非圧縮性 Newton 流体の構成方程式を仮定する。Newton 流体とは、せん断応力が速度勾配に比例するという Newton の粘性法則に従う流体のことであり、水や空気がその代表例として挙げられる。また、流速が音速に比べて非常に小さい場合、流体に関して非圧縮性が仮定できる。Newton 流体の構成方程式は以下のように与えられる。

$$\boldsymbol{\sigma} = 2\mu \mathbf{D} + \left\{ -p + \left(\kappa - \frac{2}{3}\mu \right) \text{tr} \mathbf{D} \right\} \mathbf{I} \quad (18)$$

ここで、 μ は粘性係数、 \mathbf{D} は変形速度テンソル、 p は圧力、 κ は体積粘性率を表す。また、変形速度テンソル \mathbf{D} は速度勾配テンソル \mathbf{L} の対称部分であり、次の式によって表される。

$$\mathbf{D} = \frac{1}{2} (\mathbf{L} + \mathbf{L}^T) \quad (19)$$

なお、速度勾配テンソル \mathbf{L} は次の式で表される物理量である。

$$\mathbf{L} = \frac{\partial \mathbf{v}}{\partial \mathbf{x}} = \nabla \mathbf{v} \quad (20)$$

非圧縮性流体においては $\text{tr} \mathbf{D} = 0$ が成り立つので、非圧縮性 Newton 流体の構成方程式は次のようになる。

$$\boldsymbol{\sigma} = 2\mu \mathbf{D} - p \mathbf{I} \quad (21)$$

表-1 線形トポロジー最適化の計算条件

材料：	アルミニウム
密度：	2.7g/cm ³
ヤング率：	70GPa
ポアソン比：	0.3
材料モデル：	線形弾性体
体積制約：	5%
最小セルサイズ：	1.5mm
総セル数：	1,048,576
ノード数：	8
最適化ステップ数：	50
計算時間：	20min
データセット数：	6667
訓練データ数：	6067
検証データ数：	300
テストデータ数：	300

4. データセット作成

本研究では構造力学を考慮した 3 次元形状のデータセット作成にあたって和田ら [8] が提案した Building-Cube 法 [7] を利用した線形弾性体の微小変形問題を対象としたトポロジー最適化を用いる。またオイラー型弾塑性解析によって形状ごとに付随する力学的パラメータとして用いる弾塑性ひずみエネルギーを求める。

(1) 最適化条件

本研究で用いたトポロジー最適化における条件は表-1 に示すとおりである。設計領域は中空の直方体で寸法については固定し、荷重方向を変化させることで発現するトポロジーに変化を与えデータセットを作成した。またトポロジー最適化は剛性の最大化、つまりコンプライアンスの最小化を目的として実施する。

$$\begin{aligned} \text{find:} & \quad \rho_j, \\ \text{Minimize:} & \quad \Omega = \mathbf{u} \cdot \mathbf{f}, \\ \text{Subject to:} & \quad \int \rho_j d\Omega_j \leq V_0, \\ & \quad \sum_j [k_j] \mathbf{u} = \mathbf{f}. \end{aligned}$$

ここで \mathbf{u} は変位解、 ρ は密度、 k_j は要素 j における剛性行列であり、要素中に空隙 ($\rho=0$) と母材の間の中間密度状態を許容し、密度の再分配により最終的な密度状態を決定する SIMP 法 [9] を用いる。

(2) 弾塑性解析条件

オイラー型弾塑性解析によって形状ごとに付随する力学的パラメータとして用いる弾塑性ひずみエネルギーを求めるにあたっての計算条件は表-2 に示す通りである。線形トポロジー最適化で求めた 3 次元形状の弾塑性衝突解析によって求める。なおひずみエネルギーは弾性成分と塑性成分が含まれており、塑性成分が支配的である。

表-2 弾塑性解析における物性値・計算条件

材料	アルミニウム
密度	2.7g/cm ³
ヤング率	70GPa
ポアソン比	0.3
材料モデル	弾塑性体
最小セルサイズ	0.78mm
キューブ数	1024
総セル数	4,194,304
ノード数	32
ステップ数	4000
押し込み速度	15m/s
押し込み量	6mm

5. 構造力学を考慮したニューラルネットワーク

本研究では、DeepSDF のネットワークを基に、構造力学的パラメータにより出力形状の制御を行えるようにニューラルネットワークを修正する。デコーダのネットワークに入力される値はガウス分布からランダムに取得された潜在ベクトル (313 次元), SDF サンプル点の座標 (60 次元), なお潜在ベクトルの次元数については論文 [10] と同様の値を設定した。形状に紐づいた構造力学的パラメータ (6 次元) である。なお構造力学的パラメータの値は 0~1 に正規化している。このうち SDF サンプル点の座標については本来は x, y, z の 3 次元であるが、Positional Encoding[2] を用いることによって 60 次元まで高次元に変換することにより細かい形状の再構成精度の向上を期待している。変換式については以下のように設定する。

$$\begin{pmatrix} x \\ y \\ z \end{pmatrix} \mapsto \begin{pmatrix} \sin(2^0 x), \cos(2^0 x), \dots, \sin(2^9 x), \cos(2^9 x) \\ \sin(2^0 y), \cos(2^0 y), \dots, \sin(2^9 y), \cos(2^9 y) \\ \sin(2^0 z), \cos(2^0 z), \dots, \sin(2^9 z), \cos(2^9 z) \end{pmatrix} \quad (22)$$

計算には名古屋大学が保有するスーパーコンピュータ「不老」の Type サブシステムを使用した。NVIDIA TeslaV100 の GPU を 1 基用いた。

6. 構造力学的パラメータによる条件付き生成の実施と精度の検証

本章ではテストデータの弾塑性ひずみエネルギーを用いて、指定した力学的パラメータを反映した形状をバリエーションをもって生成できるか検証を行う。形状生成に用いる構造力学的パラメータとしては弾塑性ひずみエネルギー・荷重方向 xyz ・体積・高さの 6 次元であるが、弾塑性解析は形状に対し鉛直下向きのみに作用させ、また体積や高さについては同一のため、各形状で異なる値を持つのは弾塑性ひずみエネルギーのみとなっている。本研究では 20 の弾塑性ひずみエネルギー値に対してそれぞれ 10 個形状を作成し、生成された形状に対しデータセット作成時と同条件で再度弾塑性解析を実施することで弾塑性ひずみエネルギー精度の検証を行った。結果としては図-1 と表-3 に示す通りで、各ひずみエネルギー入力値に対し概ね 90% 以上の

表-3 生成形状の弾塑性ひずみエネルギーの精度と誤差

データ数	平均精度 [%]	精度中央値 [%]	最低精度 [%]
200	97.5	98.4	67.6
	平均誤差 [J]	誤差中央値 [J]	最大誤差 [J]
	0.448	0.349	3.71

表-4 各弾塑性ひずみエネルギーによる生成形状のバリエーションの定量的評価

ひずみエネルギー (J)	データ数	chamfer distance 平均値 (mm)
12.6	20	2.07
31.1	20	0.70

精度を確認できた。また図-2 に示す通り、入力値のひずみエネルギーに対応する形状がバリエーションを持って生成されたことが確認でき、意図した確率的生成が行われていることが分かる。なお図-1 で見られた外れ値に対応する形状が図-3 であり、与えられた潜在ベクトルの乱数により形状生成がうまく行えなかったことが精度低下の原因と考えられる。

また図-4 は図-2 よりも高い弾塑性ひずみエネルギー値によって生成した形状を示しており、図-2 と比較して高い弾塑性ひずみエネルギー値では形状のバリエーションがあまり出ていない結果となった。また生成形状のバリエーションについて、以下の式で評価を行った。

$$CD(X, Y) = \frac{1}{|X|} \sum_{x \in X} \min_{y \in Y} \|x - y\|_2^2 + \frac{1}{|Y|} \sum_{y \in Y} \min_{x \in X} \|x - y\|_2^2 \quad (23)$$

なお x, y は対象とする 2 つの形状の三角形メッシュ頂点の座標、 X, Y は対象とする 2 つの形状の三角形メッシュ頂点の数を示す。これ以降この式により求まる値 $CD(X, Y)$ を chamfer distance と呼ぶ。入力値に用いた各ひずみエネルギーの値により生成された形状をランダムに 20 個ペアを作成しその chamfer distance の結果が表-4 である。この結果から入力値が 31.1J の時生成された形状が 12.6J よりもバリエーションが見られないことが分かる。この原因として入力値に用いた弾塑性ひずみエネルギーに近い値を持つ訓練形状のバリエーションが小さいことが挙げられる。表-5 は各弾塑性ひずみエネルギー帯における訓練形状をランダムに 300 個ペアを作成し chamfer distance を計算した結果である。この結果からも 31.1J 付近の訓練形状は 12.6J 付近の訓練形状と比較してバリエーションが少なく、より広いひずみエネルギーで形状のバリエーションを出すためには訓練形状の作成方法を改善する必要がある。

7. 結言

本研究においては、近年の爆発的な 3 次元形状生成 AI の進歩を構造力学設計へ応用することを目指し、線形トポロジー最適化とオイラー型弾塑性解析を組み合わせた力学的パラメータを含む 3 次元形状データセットの提案と、DeepSDF に基づく構造力学を考慮した 3 次元形状生成モデルの提案を行った。提案したモデルを用いて 20 パターンの弾塑性ひずみエネルギーによる

表-5 各弾塑性ひずみエネルギー帯における訓練形状の chamfer distance					
ひずみエネルギー帯 (J)	データ数	chamfer distance 平均値 (mm)	中央値 (J)	最大値 (J)	最小値 (J)
12.1~13.1	300	2.11	1.91×10^{-3}	4.94×10^{-3}	5.23×10^{-5}
30.6~31.6	300	0.73	0.63×10^{-3}	1.73×10^{-3}	3.52×10^{-5}




図-1 弾塑性ひずみエネルギーの入力値に対する生成精度

確率的形状生成を行い平均精度 97.5%，平均誤差 0.44J の高精度を記録した。

今後の課題として次のものが挙げられる．まずデータセットの拡張である．本研究では，線形トポロジー最適化を用いて荷重条件のみを変更し，データセットを作成した．しかしながら，この手法によって生成された訓練データにおいて，特定の弾塑性ひずみエネルギー帯において類似した形状が多く見られ，生成形状のバリエーション不足が確認できた．このため，線形トポロジー最適化において，設計領域や体積制約の変更を行い，各弾塑性ひずみエネルギーにおいて一定のバリエーションを持つ訓練データを生成することが求められる。

次に，精度の低い形状が出力された原因を追究である．構造設計への応用にあって極端に精度の低い形状が生成されることは望ましくない一方で，本研究ではその原因の追究を行えなかった．このため，ネットワークの構造や，与えられる潜在ベクトルの乱数と精度の低い生成形状との関係を調査・確認し，安定して高精度の形状を生成可能なモデルの提案を行う。

謝辞: 本研究は，HPCI システム利用研究課題（課題番号：hp220249，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 20K19815，21K14130 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*




図-2 ひずみエネルギー 12.6J により条件付き生成された 3D 形状とその形状が有するひずみエネルギーの精度

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 C: Point-e: A system for generating 3d point clouds from complex prompts, *arXiv:2212.08751*(2022).

[4] Heewoo J and Alex N : Shap-e: Generating conditional 3d implicit functions prompts, *arXiv:2305.02463*(2023).

[5] Ben P, Ajay J and Ben M: Dreamfusion: Text-to-3d using 2d diffusion content creation, *arXiv:2209.14988*(2022).

[6] Alec R, Chris H, Aditya R, Gabriel G, Sandhini A, Girish S, Amanda A, Pamela M, Jack



図-3 弾塑性ひずみエネルギーの外れ値に対応する 3D 形状




図-4 ひずみエネルギー 31.1J により条件付き生成された 3D 形状とその形状が有するひずみエネルギーの精度

ジー最適化, 日本計算工学会論文集, pp.20210019-20210019, 2021.

[9] M.P.Bendsoe, *Topology Optimization: Theory, Methods, And Applications Springer*, 2003.

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

[11] Martin P.Bendsøe and Kikuchi N.: Generationg optimal topologies in structural design using a homogenization method, *Computer Methods in Applied Mechanics and Engineering*, pp.197-224, 1988.

[12] William E. Lorensen and Harvey E.Cline : Marching cubes: A high resolution 3d surface construction algorithm, *ACM SIGGRAPH Computer Graphics*, pp.163-169, 1987.

[13] John C.Hart : Sphere tracing: A geometric method for the antialiased ray tracing of implicit surfaces, *The Visual Computer*, pp.527-545, 1996.

[14] Murat F. and Tartar L.: Optimality conditions and homogenization, *Topics in the Mathematical Modelling of Composite Materials*, pp.139-173, 1997.

[15] Kohn R. and Strang G.: Optimal design and relaxation of variational problems, *Communications on Pure and Applied Mathematics*, pp.113-137, 1986.

[16] Tokimasa S., Koji N., Rahul B., Shigenobu O. and Makoto T.: Eulerian finite volume formulation using Lagrangian marker particles for incompressible fluid-structure interaction problems, *International Journal for Numerical Methods in Engineering*, pp.11-29, 2021.

[17] Messaoud B. and Mohamed F. Harkat: Combined input training and radial basis function neural networks based nonlinear principal components analysis model applied for process monitoring, *INSTICC*, pp.483-492, 2012.

C, Gretchen K and Ilya S: Learning transferable visual models from natural language supervision, *arXiv:2103.00020*(2021).

[7] Nakahashi.K: Building-cube method for flow problems with broadband characteristic length, *International Conference on Computational Fluid Dynamics*, pp.77-81, 2022.

[8] 和田有司 西口浩司 岡澤重信 坪倉誠: Building Cube Method を利用した車体フレームのボクセルトポロ