

機械学習を用いた単層ラチスシェルの非線形力学特性の予測

Prediction of Nonlinear Mechanical Performances of Single-Layer Latticeshell Using Machine Learning

○薮内 佑馬^{*1}, 藤田 慎之輔^{*2}
Yuma YABUUCHI^{*1}, Shinnosuke FUJITA^{*2}

^{*1} 北九州市立大学大学院 国際環境工学研究科 大学院生

Graduate Student, Faculty of Environmental Engineering, The University of Kitakyushu

^{*2} 北九州市立大学大学院 国際環境工学研究科 准教授

Assoc. Prof., Graduate School of Environmental Engineering, The University of Kitakyushu, Dr. Eng.


キーワード：ラチスシェル; 形状最適化; 非線形座屈荷重; ニューラルネットワーク
Keywords：lattice shell; shape optimization; nonlinear buckling load; newral network.

1. はじめに

空間構造の一種であるシェル構造は、曲率を持った薄肉構造が面外荷重を面内力として伝達する特性を利用して効率的に大空間を可能とする構造形式である。力学的性能に優れたシェル構造の形状を経験則や勘によって決定することは困難であるため、設計の初期段階で力学的性能に優れた曲面形状を導く形状最適化手法が先行研究において数多く提案されている¹⁾。それらの研究の多くは、比較的計算負荷の低い線形弾性範囲内の力学的性能を考慮した形態創生が行われているが、扁平なシェル構造は僅かな座屈前変形でも面外力と面内力の釣合状態が大きく変化することや材料降伏の影響などから座屈荷重が大きく変動するため、非線形力学特性を考慮した形態創生の実施が望まれる。しかし、その力学特性を考慮した解析には荷重や変位を漸増させて接線剛性行列を逐次更新する釣合経路解析を要するため、構造最適化の際に繰返し参照される目的関数として扱うには計算負荷の観点から現実的でない。

一方で機械学習を用いて構造最適化に要する計算時間や計算負荷の低減を図った研究が近年盛んに行われている²⁾。筆者らは既報³⁾において、教師あり学習を用いて単層ラチスシェルの幾何学的非線形性に関する目的関数の予測モデルを構築し、十分な数の教師データを与えれば高い精度で当該目的関数の予測が可能であることを報告した。本研究では、材料非線形性に関する予測モデルの構築を行い、当該予測モデルを使用したラチスシェルの形状最適化を実施する。また、既報³⁾で構築した幾何学的非線形性に関する目的関数の予測モデルと材料非線形性に関する予測モデルを併用した形状最適化も行うことでより複雑な非線形力学特性を考慮したラチスシェルの形状最適化の計算負荷低減を図る。

2. 材料非線形性の考慮



(a) 塑性ひずみエネルギー E (b) バイリニア型 σ - ϵ 関係

図1 材料非線形解析の概要

本研究では、材料非線形性に関する目的関数であり、機械学習の予測の対象とする力学的性能として塑性ひずみエネルギー E を考慮する。本研究でいう塑性ひずみエネルギー E は材料非線形解析を行ったときの最大荷重係数到達時の全節点変位ベクトル U における荷重係数-変位曲線の面積と定義し、図1(a)中の青色で示す枠内の部分に該当する。材料非線形解析にはOpensees⁴⁾を使用し、各部材の材端にはファイバーモデルの弾塑性要素を“forceBeamColumn”により配置する。本稿での部材断面は鋼管に限定し、片端部につき鋼管を円周方向および材軸方向に10分割し、積分点を設ける。また、ファイバー要素の応力-ひずみ関係は降伏応力 σ_y を 235N/mm^2 とし、二次勾配をほぼゼロに等しい値とする図1(b)に示すバイリニアの復元力特性とする。なお、部材中央に中間節点を設けることによる個材座屈の考慮はここでは取り扱わない。

本研究では、節点変位増分ベクトル dU と外力増分ベクトルの係数 $d\lambda$ を釣合経路のパラメータとする弧長増分法を解析に用いる。経路長の増分を dl とすると、未知量 dU , $d\lambda$ は式(1)により求められる。

$$dU^T dU + d\lambda^2 = dI^2 \quad (1)$$

経路長の増分 dI を 0.01, 最大ステップ数を 1000 とし, 収束計算には修正 Newton-Raphson 法を用いる. 経路長の増分 dI を最大ステップ数へ到達するまで漸増させ, 降伏応力 σ_y へ達した部材の要素剛性マトリクスを逐次降伏後のマトリクスへ入れ替えることで材料の塑性化を考慮する.

3. B スプライン曲面によるラチスシェルの形状表現

本研究では格子グリッドで構成される単層ラチスシェルの解析対象とし, その形状表現を少数の変数で取り扱うため, その節点座標は $(I+1) \times (J+1)$ の制御ネットを有する B スプライン曲面により離散化する. 各制御点の x 座標, y 座標, z 座標を並べたベクトルをそれぞれ q_x , q_y , q_z とおくと式 (2) のように表せる.

$$q_x = (q_{x,00} \quad \cdots \quad q_{x,0J} \quad \cdots \quad q_{x,I0} \quad \cdots \quad q_{x,IJ})^T \quad (2a)$$

$$q_y = (q_{y,00} \quad \cdots \quad q_{y,0J} \quad \cdots \quad q_{y,I0} \quad \cdots \quad q_{y,IJ})^T \quad (2b)$$

$$q_z = (q_{z,00} \quad \cdots \quad q_{z,0J} \quad \cdots \quad q_{z,I0} \quad \cdots \quad q_{z,IJ})^T \quad (2c)$$

また, 節点数を n , 要素数を m とすると, 節点座標ベクトル r は式 (3) のようになる. このとき, 節点座標は式 (4) のように離散化される.

$$r = (x \quad y \quad z) \quad (3a)$$

$$x = (x_1 \quad \cdots \quad x_n)^T \quad (3b)$$

$$y = (y_1 \quad \cdots \quad y_n)^T \quad (3c)$$

$$z = (z_1 \quad \cdots \quad z_n)^T \quad (3d)$$

$$x_k = \sum_{i=0}^I \sum_{j=0}^J q_{x,ij} B_{i,N}(u_k) B_{j,M}(v_k) \quad (k = 1, \dots, n) \quad (4a)$$

$$y_k = \sum_{i=0}^I \sum_{j=0}^J q_{y,ij} B_{i,N}(u_k) B_{j,M}(v_k) \quad (k = 1, \dots, n) \quad (4b)$$

$$z_k = \sum_{i=0}^I \sum_{j=0}^J q_{z,ij} B_{i,N}(u_k) B_{j,M}(v_k) \quad (k = 1, \dots, n) \quad (4c)$$

ここで $(u_k \quad v_k)$ は k 番目の節点の節点座標に対応したパラメータであり, $B_{i,N}(u)$ は u 方向の N 次の B スプライン基底関数, $B_{j,M}(v)$ は v 方向の M 次の B スプライン基底関数を表す.

4. 機械学習の概要

本研究では, 教師あり学習の手法の一つであるニューラルネットワーク回帰を用いて, 入力層へ制御点 z 座標ベクトル q_z を入力し, 出力層で塑性ひずみエネルギー E の予測値 E^P を算出する予測モデルの構築を行う. ニューラルネットワークは図 2 に示す微分可能な変換を繋げて作られた計算グラフであり, 入力層, 中間





図 2 ニューラルネットワークの概要図

層, 出力層から構成される. 入力と出力の関係が非線形である場合は中間層のノード内で出力ベクトルから入力ベクトルへの変換を行う必要があり, この変換には正規化線形関数 ReLU と呼ばれる活性化関数を用いる. ニューラルネットワークの構築には, Python で書かれた, TensorFlow 上で実行可能な高水準のニューラルネットワークライブラリである Keras⁵⁾ を用い, 最適化アルゴリズムには Adam⁶⁾ を使用する. 損失関数は平均二乗誤差 MSE とし, 正解値 E^T に対する予測値 E^P の差を最小化する最適なパラメータ行列 W を決定する.

5. 数値解析例—形状最適化—

5.1. 解析対象物

本研究では, 図 3 に示す 12×12 の格子グリッドで構成される裁断球殻シェルの解析対象物として考慮する. 図 3 下部には初期形状の各種力学的性能も併せて示している. なお, 各記号の凡例は 5.3 節を参照されたい. スパンは $40\text{m} \times 40\text{m}$, ライズは最大 10.0m であり, 境界条



○ はピン支持を示す

$$f = 62.57[\text{kNm}], E = 307.96[\text{kNm}], \bar{V} = 26.72[\text{m}^3]$$

図 3 初期形状と初期制御点の平面図と鳥瞰図

件は図中の○で示すシェルの四隅をピン支持とする．形状は $N = M = 3$ 次の B スプライン曲面によって離散化し，制御点は $6 \times 6 (I = J = 5)$ の格子状に配置する．外力は部材の自重として 77kN/m^3 を，積載荷重として 1.0kN/m^2 を屋根面の負担面積に応じてシェルの各節点へ鉛直下向きに作用させる．ただし，材料非線形解析の増分外力には活荷重である積載荷重のみを考慮する．使用部材は $\phi 267.4 \times 6.0$ の鋼管で統一し，材料特性は鋼管の一般値としてヤング率は $2.05 \times 10^5 \text{N/mm}^2$ ，ポアソン比は 0.3 とし，接合部は剛接合と考慮する．また，本解析対象物は対称性を考慮しており，1/4 領域の制御点 z 座標ベクトル q_z を設計変数とし，その他の q_z は対称性から従属的に決定するものとする．

5.2. 予測モデルの構築

教師あり学習を行うにあたって，まずは図 3 の解析対象物における制御点 z 座標ベクトル q_z を 1/4 対称性を保たせたまま，制御点 z 座標ベクトルの下限値 $q_z^{\min}$ から上限値 $q_z^{\max}$ の範囲でランダムに変更する．ここでの $q_z^{\min}$ ， $q_z^{\max}$ はそれぞれ -5m ， 20m とする．本研究では，制御点 z 座標ベクトル q_z をランダムに変更した形状に対して，材料非線形解析を行ったビッグデータを 40,000 個作成し，教師データ 32,000 個，検証データ 4,000 個，テストデータ 4,000 個へ分割する．学習時におけるハイパーパラメータを中間層数 5 層，バッチサイズ 64，エポック数 100 とし，学習履歴における平均絶対誤差 MAE の収束率とテストデータに対する予測精度から，予測モデルを評価する．ここでいう予測精度とは，正解値 E^l と予測値 E^p の比率が $0.9 \leq E^l/E^p \leq 1.1$ の範囲に収まっている割合のことを指す．

機械学習の結果を図 4 へ示す．図 4(a) より，エポック数ごとにおける MAE および検証 MAE は小刻みに振




図 4 機械学習の結果




図 5 テストデータ内で E^l/E^p の比率が極端な代表的な形状

動しながら，学習過程で急激な発散等を起こすことなく MAE は 19.0 程度，検証 MAE は 25.0 程度へ収束している．図 4(b) より，テストデータの構成は正解値 E^l に対して昇順としており，その予測精度は $0.9 \leq E^l/E^p \leq 1.1$ の範囲で 64.23 % であり半数以上の E^l/E^p が 1.0 へ収束している傾向，正解値 E^l の値が低い形状に対しては E^l/E^p の比率の発散が大きくなっている傾向があると考ええる．

図 4(b) において， E^l/E^p の比率が最も大きい形状と小さい形状をそれぞれ図 5 へ示す．これらは，テストデータ内では比較的正解値 E^l の値が低い形状に該当する．

5.3. 形状最適化

$$\begin{aligned} & \underset{q_z}{\text{minimize}} \quad \begin{cases} -E^p \\ f \end{cases} \\ & \text{subject to} \quad \begin{cases} V \leq \bar{V} \\ q_z^{\min} \leq q_z \leq q_z^{\max} \\ 0.0 \leq z_{\min} \end{cases} \end{aligned} \quad (5)$$

$$\begin{aligned} & \underset{q_z}{\text{minimize}} \quad \begin{cases} -E^p \\ -\lambda^p \\ f \end{cases} \\ & \text{subject to} \quad \begin{cases} V \leq \bar{V} \\ q_z^{\min} \leq q_z \leq q_z^{\max} \\ 0.0 \leq z_{\min} \end{cases} \end{aligned} \quad (6)$$

- E^p : 塑性ひずみエネルギーの予測値
- λ^p : 非線形座屈荷重係数の予測値³⁾
- f : 線形弾性ひずみエネルギー
- q_z : 制御点 z 座標ベクトル
- $q_z^{\max}$: q_z の上限値
- $q_z^{\min}$: q_z の下限値
- V : ラチスシェルの総体積
- $\bar{V}$: ラチスシェルの総体積の上限値
- $z_{\min}$: 最小の z 軸節点座標

本研究では，塑性ひずみエネルギーの予測値 E^p と線形弾性ひずみエネルギー f を目的関数とした式 (5)，既報³⁾と同様の手法で構築した幾何学的非線形性に関する力学的性能である非線形座屈荷重係数の予測値 λ^p をさらに目的関数として加えた式 (6) の 2 種類の多目的形状最適化問題を発見的最適化手法ソルバー MIDACO⁷⁾を用いて 12 時間解析を行うことで解く．非線形座屈荷重係数の予測値 λ^p は幾何学的非線形解析を行ったときのラチスシェルのスパン $\times 1/10$ までの変形領域における最大荷重係数値であり，5.2 節で説明した $0.9 \leq \lambda^l/\lambda^p \leq 1.1$ の割合による評価方法で約 90 % 以上の精度が確保できることを確認している．制約条件として，初期形状の総体積 V を最適化時の総体積の上限値 $\bar{V}$ として考慮し，サイズが極端に低いもしくは高い形状を避けるため，制御点 z 座標ベクトルの下限値 $q_z^{\min}$ ，上限値 $q_z^{\max}$ はそれぞ






図6 最適化問題 (5) のパレートフロント



(a) 塑性ひずみエネルギーの真の値 E^t が最大の形状



(b) 線形弾性ひずみエネルギー f が最小の形状

図7 最適化問題 (5) で得られた代表的な解形状






図8 最適化問題 (6) のパレートフロント



(a) 塑性ひずみエネルギーの真の値 E^t が最大の形状



(b) 非線形座屈荷重係数の予測値 λ^p が最大の形状

図9 最適化問題 (6) で得られた代表的な解形状

れ -5.0m , 20.0m とする。最適化時の塑性ひずみエネルギーの予測値 E^p および非線形座屈荷重係数の予測値 λ^p は機械学習による予測，線形弾性ひずみエネルギー f は Opensees⁴⁾ による線形弾性解析により算出する。

最適化問題 (5) および (6) の形状最適化の結果を図6および図8に示す。また、これらの最適化問題で得られた代表的な形状を図7および図9へ示す。図6および図8には、パレートフロント上の E^p に対し、材料非線形解析を実施して算出した真の値 E^t も併せて示している。図6でのパレートフロント上の E^t/E^p の比率は全て 0.9 から 1.1 の範囲内に収まっていることから予測モデルが精度良く予測可能な範囲内で当該目的関数は最大化されていると考える。図8では λ^p の値の高い形状に対して E^t/E^p の比率が大きくなっている傾向があり、最大で 1.46 程度となっている。教師データを増やすなどして多様な形状に対する予測精度が向上すると、図6および図8に示すパレートフロントは変化する可能性があると考えられる。本予測モデルは図7(a)に示すようなシェル中央部が凹となっている形状を塑性ひずみエネルギー E の値が高い形状であると評価する傾向があると考えられる。

6. 結論

本研究では、構造最適化時に計算負荷の高い非線形解析により算出される目的関数を機械学習による予測へ代替する手法を提案した。予測精度は教師データの数と予測させる目的関数の設定方法に依存する傾向があるが、

当該予測モデルを用いた形状最適化を実施すれば非線形力学特性を考慮した構造最適化に要する計算負荷低減へ寄与できると考える。ただし、得られる形状は予測モデルが精度良く予測できる範囲内におけるものである可能性に留意する必要がある。

7. 謝辞

本研究の一部は JSPS 科研費 22K04416 の助成を受けたものである。ここに記して謝意を表する。

【参考文献】

- 1) 藤田慎之輔, 大崎純. パラメトリック曲面で定義されたラチスシェルの部材長一様化と剛性最大化を目的とした形状最適化. 日本建築学会構造系論文第 78 巻, Vol. 685, pp. 495–502, 2013.3.
- 2) 林和希, 大崎純. グラフ埋め込みと機械学習による単層ラチスシェルの弾性座屈荷重低減係数の予測. 令和 4 年度日本建築学会 近畿支部研究発表会, pp. 73–76, 2022.
- 3) Y. Yabuuchi and S. Fujita. Structural optimization of lattice shells with geometric nonlinearity using machine learning. *Proceedings of the IASS Annual Symposium 2023 Integration of Design and Fabrication 10-14 July 2023, Melbourne, Australia*, 2023.7.
- 4) M. Zhu, F. McKenna, and M. Scott. Openseespy: Python library for the opensees finite element framework. *SoftwareX*, Vol. 7, pp. 6–11, 2018.1.
- 5) François Chollet, et al. Keras. <https://keras.io>, 2015.
- 6) Jimmy Lei Ba Diederik P. Kingma. Adam: A method for stochastic optimization. *3rd International Conference on Learning Representations, ICLR2015*, 2015.
- 7) M. Schlueter, J. A. Egea, and J. R. Banga. Extended ant colony optimization for non-convex mixed integer nonlinear programming. *Computers & Operations Research*, Vol. 36, No. 7, pp. 2217–2229, 2008.8.