

離散曲率を用いた機械学習によるシェル構造物のひずみ予測 Strain Prediction of Shell Structures by Machine Learning using Discrete Curvature

○早川 健太郎*1, 大崎 純*2
Kentaro HAYAKAWA*1 and Makoto OHSAKI*2

*1 京都大学大学院工学研究科建築学専攻 特定助教 博士 (工学)

Program-Specific Assistant Professor, Department of Architecture and Architectural Engineering, Kyoto University, Dr. Eng.

*2 京都大学大学院工学研究科建築学専攻 教授 博士 (工学)

Professor, Department of Architecture and Architectural Engineering, Kyoto University, Dr. Eng.

キーワード：ニューラルネットワーク；シェル構造物；ひずみ分布；離散ガウス曲率；離散平均曲率

Keywords: neural network; shell structure; strain distribution; discrete Gaussian curvature; discrete mean curvature.

1. はじめに

シェル構造物のひずみや応力分布を測定することは構造ヘルスマニタリングにおいて重要である。特に、自由曲面連続体シェルのひずみや応力分布を直接計測することは困難なため、構造物の変形からこれらを推定する必要がある。構造物の変形はレーザー測量や写真測量^{1,2)}などを用いて得られる構造物上の点群データから計算可能であり、一般的に点群の並進変位として得られる。しかし、構造物上の点の回転変位は不明であり、並進変位のみが利用可能である場合が多い。シェル構造のように曲げ応力が生じる場合には回転変位も重要な情報であり、ひずみや応力分布の予測精度に大きく影響すると考えられる。

本稿では、ニューラルネットワークを用いた機械学習により、構造物上の点の並進変位からシェル構造のひずみを予測する。構造物は三角形シェル要素で離散化されているものとする。汎用性を考慮すると、シェル形状や要素分割に依存しないような学習モデルを構築することが望ましい。そこで、三角形シェル要素ごとに、節点変位等の情報を用いてひずみの予測を行う。多くの場合で節点の並進変位のみが利用可能で回転変位の情報が不足していること、隣り合う要素同士の相互作用を反映した入力データが存在すべきであることを考慮して、ニューラルネットワークの入力データに節点で定義される離散ガウス曲率および離散平均曲率ベクトル^{3,4)}の変化量を加える。本稿では、有限要素解析ソフトウェアを用いた構造解析結果に対して、曲率変化量を考慮した学習と考慮しない学習のひずみ予測精度を比較することで、曲率変化量を考慮することにより予測精度が向上することを示す。

2. 離散曲率

本節では、三角形メッシュで表される離散曲面の内部頂点における離散ガウス曲率および離散平均曲率ベクトル




図1 離散曲面上の内部頂点まわりの諸量

の文献^{3,4)}による定義を示す。

図1のように離散曲面の頂点 i の位置ベクトルを $\mathbf{r}_i \in \mathbb{R}^3$ 、頂点 i の周囲のVoronoi領域 Ω_i の面積を $A_i \in \mathbb{R}$ とする。また、頂点 i に接続する n_i 本の辺の頂点 i と反対側の頂点の位置ベクトルを反時計回りにそれぞれ $\mathbf{r}_{i,j} \in \mathbb{R}^3$ ($j=1, \dots, n_i$) とする。 $\theta_{i,j}$ を $\mathbf{r}_{i,j} - \mathbf{r}_i$ と $\mathbf{r}_{i,j+1} - \mathbf{r}_i$ のなす角とすると、頂点 i での離散ガウス曲率 K_i は以下のように定義される^{3,4)}。

$$K_i = \frac{1}{A_i} \left(2\pi - \sum_{j=1}^{n_i} \theta_{i,j} \right) \quad (1)$$

ただし、 $\mathbf{r}_{i,n_i+1} = \mathbf{r}_{i,1}$ とする。

図1のように $\alpha_{i,j}$ 、 $\beta_{i,j}$ をそれぞれ $\mathbf{r}_{i,j} - \mathbf{r}_{i,j-1}$ と $\mathbf{r}_i - \mathbf{r}_{i,j-1}$ 、 $\mathbf{r}_{i,j} - \mathbf{r}_{i,j+1}$ と $\mathbf{r}_i - \mathbf{r}_{i,j+1}$ のなす角とする。ただし、 $\mathbf{r}_{i,0} = \mathbf{r}_{i,n_i}$ とする。このとき、頂点 i での離散平均曲率ベクトル $\mathbf{H}_i \in \mathbb{R}^3$ は以下のように定義される^{3,4)}。

$$\mathbf{H}_i = \frac{1}{2A_i} \sum_{j=1}^{n_i} (\cot \alpha_{i,j} + \cot \beta_{i,j}) (\mathbf{r}_i - \mathbf{r}_{i,j}) \quad (2)$$

3. 機械学習モデル

3.1. 入出力データ

本稿ではニューラルネットワークを用いて三角形シェル要素の表面および裏面の積分点 j ($=1,2$) における全体座標系での x, y 方向ひずみ $\varepsilon_{jx}, \varepsilon_{jy}$ とせん断ひずみ γ_{jxy} の計6成分をそれぞれ個別の学習モデルで予測する。離散ガウス曲率および離散平均曲率ベクトルは内部節点のみで

定義されるため、ひずみ予測は内部要素（外周部以外の要素）のみで行う。なお、学習時、精度検証時ともにそれぞれの入力データは訓練用データの平均値との差をとったうえで、訓練用データの標準偏差で割ることで標準化する。また、ひずみは 10^4 倍した値で学習する。




図2 ニューラルネットワークの入出力データ

入力データは図2および以下に示す合計28成分である。

- ・ シェル厚さ $t \in \mathbb{R}$ (1成分)
- ・ 変位前の座標において節点1から節点2, 3に向かうベクトル $\mathbf{e}_{12}, \mathbf{e}_{13} \in \mathbb{R}^3$ ($2 \times 3 = 6$ 成分)
- ・ 3節点の並進変位ベクトル $\mathbf{u}_1, \mathbf{u}_2, \mathbf{u}_3 \in \mathbb{R}^3$ ($3 \times 3 = 9$ 成分)
- ・ 3節点でのガウス曲率変化量 $\Delta K_1, \Delta K_2, \Delta K_3 \in \mathbb{R}$ ($1 \times 3 = 3$ 成分)
- ・ 3節点での平均曲率ベクトル変化量 $\Delta \mathbf{H}_1, \Delta \mathbf{H}_2, \Delta \mathbf{H}_3 \in \mathbb{R}^3$ ($3 \times 3 = 9$ 成分)

上記のデータで学習およびひずみ予測を行う場合を本稿ではケースcとよぶ。さらに、曲率変化を考慮した場合のひずみ予測精度の比較対象として、上記の入力データから曲率変化量を省いたケースu、および曲率変化量の代わりに節点の回転変位 $3 \times 3 = 9$ 成分を用いたケースdによる学習と予測も実行する。




図3 学習データ生成用基準曲面

3.2. 学習データの生成

図3に示す 10×10 mの正方形平面をもつ2種類の曲面上にグリッド状に配置された点を基準として、それぞれのグリッド点を z 方向に ± 0.5 m ランダムに移動させたものを補間するよう学習データ用のシェル構造の曲面をそれぞれ200個生成する。生成された合計 $200 \times 2 = 400$ 個の曲面を要素の目標辺長を600 mmから1000 mmまで100 mm

刻みで変化させて5種類のメッシュサイズに三角形分割し、図4に示す例のような合計 $400 \times 5 = 2000$ 個の構造解析用三角形メッシュを生成する。




図4 学習データ生成に用いたシェル構造の例

構造解析での支持点は全てピン支持とし、図4の黒い点で示すように隅部の3節点とその他の外周節点をランダムに支持する。合計2000個の三角形メッシュそれぞれに対して構造物全体で一定のシェル厚さを50~200 mmの範囲でランダムに3種類ずつ設定し、大きさを自重の1~10倍の範囲でランダムに設定した z 軸負の向きの荷重を厚さの異なる3種類のシェルに共通して与える。以上のようにシェル構造を生成し、合計 $2000 \times 3 = 6000$ 件、内部要素数計1943493個の構造解析を行う。材料は鉄筋コンクリートを想定し、重量密度 22.54 kN/m^3 、ヤング率 $2.5 \times 10^7 \text{ kN/m}^2$ 、ポアソン比0.2とする。構造解析にはAbaqus 2022⁵⁾を用い、材料は線形として、幾何学的非線形のみを考慮する。

3.3. ニューラルネットワークの構成

学習モデルはPythonの機械学習ライブラリであるPyTorch⁶⁾を用いて作成する。ニューラルネットワークの隠れ層数、各隠れ層のユニット数は学習対象のひずみの種類、入力データの選択にかかわらずそれぞれ3, 60とし、活性化関数にはSELU (Scaled Exponential Linear Unit)を用いる。また、損失関数は平均2乗誤差、最適化アルゴリズムはAdamを用いる。バッチサイズ、エポック数はそれぞれ200, 500とした。その他のパラメータはいずれもPyTorchのデフォルト値を用いる。

4. ニューラルネットワークによる学習結果とその検証

4.1. 学習結果

1943493個の内部要素のデータの80%を訓練用データ、残りの20%を検証用データとして学習を行う。ケースc, u, dの学習過程における損失関数の値の推移はそれぞれ図5, 6, 7に示すとおりである。いずれの損失関数の値もほぼ一定値に収束しており、ひずみの値を学習できている。訓練用データと検証用データに対する値はおおよそ等しく、 x, y 方向ひずみ $\epsilon_{jx}, \epsilon_{jy}$ に対してせん断ひずみ γ_{jxy} ($j=1,2$) に関する値の方がいずれのケースにおいても大きい。




図5 ケースcの学習過程




図6 ケースuの学習過程




図7 ケースdの学習過程




図8 精度検証用シェル構造

4.2. 未学習のシェルによる精度検証

学習に使用していない形状、荷重条件のシェルに対するひずみ予測の精度検証を行う。シェル形状、要素分割パターン、支持条件は図8に示すとおりである。シェル厚さ100, 200, 300 mmの3パターンに対して、それぞれ自重の1, 10, 100倍の z 軸負の向きの荷重を与える。

図9にケースc, u, dのそれぞれにおいてシェル厚さと荷重を変えた各9通りのひずみ予測の誤差の分布を示す。予測誤差は、厚さと荷重の異なる構造物ごとに評価し、ひずみの予測値から構造解析による正解値を引いたものをひずみの正解値の絶対値平均で割ったものとする。なお、一

部のシェル厚さ、荷重における予測誤差は他の場合と比較してかなり大きい場合がある。

図5, 6の比較および図9に示すように、曲率変化量を入力したケースcにおいて、予測誤差とそのばらつきが節点の並進変位のみを考慮したケースuよりもおおむね小さい。一方、節点の回転変位を入力に加えたケースdと比較すると、多くの解析例でひずみの予測精度は同等またはケースuとの中間程度で、実構造物で計測が困難な回転変位を含む完全な節点変位の情報をもとにひずみを予測した場合と比較しても、ケースcでは良好な予測精度が得られている。また、ひずみの成分間で予測精度を比較するとせん断成分は他の2成分と比較して精度が低い。学習していないシェル厚さや荷重においては、ひずみの大きさが学習時のデータに近いと考えられるものでは比較的良い精度の予測がケースc, u, dのいずれの場合もできているものの、シェル厚さ300 mmかつ自重の1倍の荷重を与えた場合のようにひずみの値が小さい例では大きな誤差が生じている。

シェル厚さ200 mm、自重の1倍の荷重を与えた場合の構造解析結果を図10に、ケースcでの予測誤差を図11に示す。予測誤差の絶対値平均はいずれのひずみ成分でもケースd < ケースc < ケースuの順に小さい。図11において、予測誤差分布にばらつきはあるものの、境界付近やひずみの変化が大きい領域で予測誤差が大きい傾向がある。

5. まとめ

本稿では、ニューラルネットワークを用いた機械学習により、三角形シェル要素のひずみを予測した。入力に要素節点の並進変位だけでなく離散ガウス曲率と離散平均曲率ベクトルの変化量を加えることで、並進変位のみを考慮した場合と比較して、より幅広いシェル厚さと荷重の大きさに対し、実測が困難な節点の回転変位を用いずとも精度よくひずみを予測できることを示した。

[参考文献]

- 1) 武藤 厚, 中根健太, 伊勢野幸菜, 小松宏年, 鐘江美帆: 大型RCシェルの長期変形と構造特性に関する実証的研究(その8) 建設から10年間の経時変化(変形状), 日本建築学会大会学術講演梗概集, 構造I, pp. 629–630, 2021
- 2) 李 陽洋, 川口健一, 中楚洋介, 武藤 厚, 松本慎也: 既存建物の3次元計測と計測点群からの有意データ抽出手法, 日本建築学会技術報告集, Vol. 28, No. 68, pp. 133–138, 2022
- 3) J. M. Sullivan, Curvature measures for discrete surfaces, in: Proc. SIGGRAPH 2006, Boston, USA, W. Finnegan and D. Shreiner (Eds.), Assoc. Computing Machinery, pp. 10–13, 2006
- 4) M. Meyer, M. Desbrun, P. Schröder and A. H. Barr, Discrete differential-geometry operators for triangulated 2-manifolds, in Visualization and Mathematics III, H. C. Hege and K. Polthier (Eds.), Springer, pp. 35–57, 2003
- 5) Dassault Systèmes, Abaqus 2022 documentation, 2022
- 6) PyTorch, <https://pytorch.org/> (アクセス日: 2023.9.22)




図9 ひずみの予測誤差分布 (縦軸の凡例は「シェル厚の上1桁」-「荷重の倍率」-「解析ケース」)




図10 検証用シェルの内部要素のひずみ分布 (シェル厚 200 mm, 自重の1倍の z 方向荷重)




図11 検証用シェルのケースcでのひずみ予測誤差分布 (シェル厚 200 mm, 自重の1倍の z 方向荷重)