

周辺ピン支持された単層円筒ラチスシェルの振動モードの特徴量抽出

Feature extraction of vibration modes of a pin-supported single-layer cylindrical reticulated shell

○小山 真人^{*1}, 瀧内 雄二^{*2}, 中澤 祥二^{*3}
Masato KOYAMA^{*1}, Yuji TAKIUCHI^{*2}, Shoji NAKAZAWA^{*3}

*1 豊橋技術科学大学 大学院生

Graduate Student, Toyohashi University of Technology

*2 豊橋技術科学大学 助教 博士(工学)

Assistant Professor, Toyohashi University of Technology, Dr.Eng.

*3 豊橋技術科学大学 教授 博士(工学)

Professor, Toyohashi University of Technology, Dr.Eng.

Summary: This study proposes a feature extraction method for analyzing the vibrational properties of cylindrical reticulated shell structures. The feature extraction method consists of two schemes: imaging of vibration modes and dimensionality reduction of image data. As a fundamental step in the research, the accuracy of the imaging of the vibration modes is first discussed. Then, for the dimensionality reduction of the image data, a variational autoencoder is employed and the dimensionality of the feature values of the vibration modes is discussed. The features are computed on the basis of a data set consisting of the vibrational properties of 10000 single-layer cylindrical reticulated shells. Through feature-based data mining, the dominant vibration mode shapes in the vibrational properties of single-layer reticulated shells are analyzed, and the usefulness of the proposed feature extraction method is discussed.

キーワード: 特徴抽出; 円筒ラチスシェル; 振動モード; 変分オートエンコーダ

Keywords: Feature extraction; Cylindrical reticulated shell structure; Vibration mode; Variational auto-encoder

1. はじめに

鉄骨部材を網目状かつ単層に配置して大スパンを覆う単層ラチスシェル構造は空間構造の中でもよく利用される構造形態である。その中でも円筒形状の単層円筒ラチスシェルは学校体育館などで広く利用され、地震時には避難施設として利用されることも多く、高い耐震性が求められる。しかし、単層円筒ラチスシェル構造は水平方向の地震入力に対し、鉛直方向の振動モードが複数励起する複雑な振動性状を有する。¹⁾

本研究で対象とする単層円筒ラチスシェルに関してこれまで様々な研究^{2,3)}が行われているが、Takiuchiら⁴⁾は周辺がピン支持の単層円筒ラチスシェルについては2個の主要な振動モードで地震荷重を表現することができることを明らかにしている。しかし、この2個の主要な振動モードは、単層円筒ラチスシェルの形状や部材断面などの変数により多様に変化し、その関係性は明らかになっていない。また、通常この種の構造物の主要な振動モードを求めるためには数百個の固有値を求める必要があり、やや手続きが煩雑になる。このため固有振動解析なしに円筒ラチスシェルの主要2モードを予測することが

できれば、この種の構造物の耐震設計に有用である。

このような解析結果を予測する手法の一つとして、近年機械学習に注目が集まっている。一般的に機械学習では分析する対象のデータの特徴を表す特徴量を指定する必要があり、適切な特徴量の選択が機械学習の精度に影響することが知られている。また、特徴量が増えるほど精度良く予測を行うためのデータ数が多くなることを「次元の呪い」と呼び、機械学習の分野では周知の事実となっている。構造工学分野の機械学習における特徴量の選択例を確認すると、Zhangら⁵⁾は地震動データを時系列データとして扱い、Ohら⁶⁾は地震動データを画像データに変換し、機械学習モデルに適用している。また、Hayashiら⁷⁾は2次元トラスをグラフ構造として扱い強化学習を行っている。このように、適切に特徴量を選択することが前述の振動モードを予測するためにも必要であると考えられる。しかし、振動モードは構造物の自由度に応じてサイズが変化するため、直接振動モードのデータの特徴量とすることは難しい。また、振動モードの形状に注目しても機械学習に利用する多くのデータを目視で確認することは現実的ではない。

そこで本研究では、ラチスシエルの地震荷重を設定する基礎的な研究として、振動モードから特徴量を抽出する手法を構築することを目的とする。具体的には、振動モードをまず画像データに変換し、変分オートエンコーダを用いて、画像データを圧縮する方法である。本研究では 10000 件の円筒ラチスシエルのデータを基に、振動モードの特徴抽出を試み、提案手法の妥当性を議論するとともに、特徴量と円筒ラチスシエルのパラメータの関係性の分析を行う。




図 1 解析モデル

2. 解析モデル

2.1. 解析モデルの生成

解析モデルは、図 1 に示す周辺をピン支持とした正三角形網目の円筒ラチスシエルとする。ラチスシエルは、スパン L_Y 、半開角 ϕ 、メッシュの桁方向の分割数 n_x 、アーチ方向の分割数 n_y 、細長比 λ_0 、固定荷重に対する安全率 ν を表 1 に示す範囲で一様乱数を用いて 10000 個作成する。固定荷重は 1.0 kN/m^2 の等分布荷重を想定する。部材は鋼管を想定し、接合部は剛接合とする。部材のヤング係数 E を 205000 N/mm^2 、降伏応力 $\sigma_y = 235 \text{ N/mm}^2$ とする。鋼管断面は正三角形パネルの部材長 l_0 から式(1)より外径 D を定める。

$$D = 2\sqrt{2} l_0 / \lambda_0 \quad (1)$$

管厚は既往研究⁸⁾を参照し、修正 Dunkerley 式より推定した座屈耐力が固定荷重に対する安全率を満たすように定める。

2.2. 着目するモード

本研究では、次式のひずみエネルギー比 ε_i が大きい振動モードを主モードと定義し、特徴量を抽出する。

$$E_i = \frac{1}{2} \mathbf{u}_i^T \mathbf{K} \mathbf{u}_i (\beta_i \cdot S_D(T_i))^2 \quad (2)$$

$$\varepsilon_i = \frac{E_i}{\sum_{i=1}^N E_i} \quad (3)$$

ここで、 \mathbf{u}_i は構造物の i 次の振動モードを表し、 β_i は刺激係数、 T_i は固有周期を表す。本研究では、応答解析において Y 方向に地震動入力を行うことを想定する。そのため、 β_i は Y 方向の成分を用いる。 \mathbf{K} は構造物の剛性マトリクスを表す。 S_D は設計用の変位応答スペクトルを表し、本研究では国土交通省告示スペクトル（第 2 種地盤）とする。減衰によるスペクトルの応答低減率 D_h は笠井ら⁹⁾による式(4)を利用する。

$$D_h = \sqrt{\frac{1 + \alpha h_0}{1 + \alpha h}} \quad (4)$$

ここで、 $\alpha=75$ 、 $h_0=5\%$ 、 $h=2\%$ とする。式(3)の N は考慮するモード数を表し、

$$\sum_{i=1}^N \rho_i \geq 0.9 \quad (5)$$

を満足するように十分大きな数とする。ここで、 ρ_i は Y 方向の有効質量比を表す。

3. 振動モードの画像変換とその適用範囲

3.1. 振動モードの画像への変換

構造物の振動モードは、構造物の自由度に応じてそのデータ長が変化する。そこで、本研究では、振動モードの特徴量抽出のための前処理として、振動モードを画像化することを提案する。この操作により、自由度の異なる構造物をニューラルネットワークなどで取り扱うことがより容易になる。本研究では振動モードを画像データに変換する過程を画像変換と呼び、得られる画像データを以後、モード画像 C と呼ぶ。

画像変換の概要を図 2 に示す。モード画像は、各画素が赤、緑、青の 3 つの要素で色を表す RGB カラー形式を採用する。モード画像の縦横の画素数を N_p とすると、1 つの振動モードは $N_p \times N_p \times 3$ (赤、緑、青) の 3 次元配列でデータを格納する。本研究では、事前の解析により画素数 N_p は 50 とする。振動モードの X 成分は画素の赤に、Y 成分は緑に、Z 成分は青に対応する。構造物のノード s の座標 $\mathbf{p}_s = \{x_s, y_s, z_s\}^T$ は、式(6)のように画像中の座標 $\bar{\mathbf{p}}_s = \{\bar{x}_s, \bar{y}_s\}^T$ に変換される。

$$\begin{bmatrix} N_p/L_x & 0 & 0 \\ 0 & N_p/L_y & 0 \end{bmatrix} \begin{Bmatrix} x_s \\ y_s \\ z_s \end{Bmatrix} = \begin{Bmatrix} \bar{x}_s \\ \bar{y}_s \end{Bmatrix} \quad (6)$$

ここで、式(6)における L_x は X 方向のスパン、 L_y は Y 方向のスパンである。画素の中心の座標と、構造物の節点を修正して式(6)で投影した座標 $\bar{\mathbf{p}}_s$ の距離を求め、 $\bar{\mathbf{p}}_s$ に最も近い画素に $\bar{\mathbf{p}}_s$ の振動モード成分を採用する。反対に、モード画像からモードを計算する際（以後、逆変換とよぶ）は式(6)より構造物のノード \mathbf{p}_s の成分を、 $\bar{\mathbf{p}}_s$ に最も近い画素のデータより参照し計算する。なお、図 2 のようなモード画像は 0 ~ 255 の整数値で保存する必要があるが、後述の VAE を用いた振動データの次元削減では、振動モード値から算出した実数の 3 次元配列データ ($N_p \times N_p \times 3$) を用いる。

節点のモード成分は X, Y, Z 方向の並進成分 \mathbf{U} と X, Y, Z 軸回りの回転成分 $\boldsymbol{\Theta}$ を有しているが、上述の画像変換

では並進成分のみをデータ化することになる。ただし、次式の操作から振動モードの回転成分を再計算することができる。

$$\omega^2 \mathbf{M} \begin{Bmatrix} \mathbf{U} \\ \boldsymbol{\Theta} \end{Bmatrix} = \begin{Bmatrix} \mathbf{P} \\ \mathbf{0} \end{Bmatrix} = \mathbf{K} \begin{Bmatrix} \mathbf{U} \\ \boldsymbol{\Theta} \end{Bmatrix} = \begin{bmatrix} \mathbf{K}_{11} & \mathbf{K}_{12} \\ \mathbf{K}_{21} & \mathbf{K}_{22} \end{bmatrix} \begin{Bmatrix} \mathbf{U} \\ \boldsymbol{\Theta} \end{Bmatrix} \quad (7)$$

$$\boldsymbol{\Theta} = -\mathbf{K}_{22}^{-1} \mathbf{K}_{21} \mathbf{U} \quad (8)$$

ここで、 ω は固有円振動数、 \mathbf{M} は質量マトリクスを表す。式(7)において本研究では、回転方向の質量を0としており、回転慣性は考慮しない。 \mathbf{U} と $\boldsymbol{\Theta}$ を組み合わせたモードを \mathbf{u}' とすると、モード画像から振動モードを再構築して得られる固有円振動数 ω' は式(9)より求められる。

$$(\omega')^2 = \frac{\mathbf{u}'^T \mathbf{K} \mathbf{u}'}{\mathbf{u}'^T \mathbf{M} \mathbf{u}'} ; \mathbf{u}' = \begin{Bmatrix} \mathbf{U} \\ \boldsymbol{\Theta} \end{Bmatrix} \quad (9)$$

\mathbf{u}' と ω' から固有周期や刺激係数などの固有振動パラメータを算出する。




図2 振動モードの画像変換の概要


3.2. 円筒ラチスシェルの固有振動性状と振動モードの画像化

一例として $L_Y = 22.2$ [m], $\phi = 59.5$ [deg], $n_X = 14$, $n_Y = 12$, $\lambda_0 = 52.9$, $\nu = 3.5$ の円筒ラチスシェル (Model1) を固有振動解析して得られた結果を表2に示す。表より、6次と9次のモードの ε_i が大きく、地震時の変形に大きく寄与するモードであるといえる。本研究では、6次モードのように ε_i が1番大きいモードを主モードと呼ぶ。主モードを図3に示す。主モードはアーチ方向に半波数が4あるが、アーチ中央のモード振幅は外側の振幅に比べて小さい。

表と同様に、10000個のすべての構造モデルに対してひずみエネルギー比を算出し主モードを抽出した。

表2 Model1の固有振動性状

i	T_i [sec]	β_i	ρ_i	ε_i
2	0.442	-0.242	0.001	0.004
6	0.250	-5.353	0.329	0.649
9	0.210	3.775	0.164	0.227
10	0.208	2.497	0.072	0.098
24	0.131	1.157	0.015	0.007
42	0.103	1.828	0.038	0.008
57	0.090	-0.702	0.006	0.001
65	0.086	0.569	0.004	0.000
151	0.041	3.919	0.177	0.003
154	0.033	-2.680	0.083	0.001



(6次モード)

図3 主モードの振動モードとモード画像

3.3. 画像化と逆変換の精度

画像化の精度を分析するために、円筒ラチスシェル ($L = 35.0$ [m], $n_X = 10$, $n_Y = 12$, $\lambda_0 = 40.0$, $\nu = 5.0$) の半開角 ϕ を 30, 60, 70, 80, 90 [deg] とライズを変化させたモデルを作成した。固有振動解析より得られた主モードの振動モード \mathbf{u} と \mathbf{u}' の比較を図4に示す。図4の縦軸の決定係数 R_u^2 は次式より計算する。

$$R_u^2 = 1 - \frac{\sum_{j=1}^D (u_j - u'_j)^2}{\sum_{j=1}^D (u_j - \mu_u)^2} \quad (10)$$

ここで u_j, u'_j は \mathbf{u}, \mathbf{u}' の節点 j の各成分、 μ_u は \mathbf{u} の平均値、 D は構造物の節点数を示す。 R_u^2 は1.0に近いほど \mathbf{u} と \mathbf{u}' の差が小さく、画像変換、逆変換の精度が高いことを表す。表3は固有振動解析より得られた固有周期 T と \mathbf{u}' から式(10), (11)を用いてモードの回転成分を計算し、回転成分を考慮した \mathbf{u}' から算出した固有周期 T' を求めた結果を示す。

図4より、画像変換、逆変換は $\phi = 30 \sim 80$ [deg] のモデルにおいて $R_u^2 = 1.0$ の精度を有していることが確認できる。また、表3より、全モデルにおいて T と T' の差はなく、精度良くデータ間の変換ができておりといえる。

ライズが高い場合に画像変換の精度が悪化している原因としては、 $\phi = 90$ [deg] のモデルの桁方向境界付近において平面投影した際に多くの節点が集中し、一部のモードデータが欠損したことが考えられる。本研究では式(9)のように、節点のZ方向の影響を無視して画像化を行ったが、円筒の接線方向と法線方向にモードを分解することも代替案として考えられる。この点は今後の課題とする。なお、本研究で検討するデータは表1に示すように ϕ が 30 ~ 60 [deg] の範囲にあるため、画像変換による情報の喪失はほぼ無視できると考えられる。




図4 半開角 ϕ と画像変換の精度 R_u^2 の関係

表3 半開角毎の固有周期 T と画像変換後の固有周期 T'

ϕ [deg]	T [sec]	T' [sec]
30	0.346	0.346
60	0.234	0.234
70	0.232	0.232
80	0.237	0.237
90	0.244	0.244

4. 変分オートエンコーダを用いた特徴量抽出

4.1. 変分オートエンコーダ

本研究では3章で画像化した振動モードのデータに対し、変分オートエンコーダ¹⁰⁾ (Variational auto-encoder 以下, VAEと表記する)を用いて振動モードの特徴量を抽出する。VAEは図5に示すように、入力データを特徴量 \mathbf{z} に圧縮するエンコーダと、特徴量 \mathbf{z} から入力データを復元して出力するデコーダの2種類のネットワークにより構成される教師なし学習モデルである。入力したデータ(モード画像)を出力層で再構築するように学習させると、入力データの特徴を捉えた特徴量 \mathbf{z} が抽出できる。




図5 VAEの概要

VAEでは学習した \mathbf{z} の値が多変量正規分布に近づくように学習を行い、入力画像よりエンコーダで平均ベクトル $\boldsymbol{\mu}$ と共分散行列 $\boldsymbol{\Sigma}$ を求める。機械学習での損失関数 L は次式からなる。

$$L = \beta L_R + D_{KL}[N(\boldsymbol{\mu}, \boldsymbol{\Sigma}) \| N(\mathbf{0}, \mathbf{I})] \quad (11)$$

$$L_R = \frac{1}{M} \sum_{k=1}^M (x'_k - x_k)^2 \quad (12)$$

$$D_{KL}[q(x) \| p(x)] = \int_{-\infty}^{\infty} q(x) \log \frac{q(x)}{p(x)} dx \quad (13)$$

ここで L_R は再構築誤差関数と呼ばれ、入力データと再構築した出力データがどの程度近いかを表している。入力データを \mathbf{x} とし、その要素 k を x_k と表記する。また、VAEの出力を \mathbf{x}' とし、その要素 k を x'_k とし、 M は入力データの要素数である。ここで D_{KL} はカルバックライブラー情報量と呼ばれ、2個の確率分布間の差異を表す尺度であり、 $N(\boldsymbol{\mu}, \boldsymbol{\Sigma})$ が多変量標準正規分布 $N(\mathbf{0}, \mathbf{I})$ に近づくほど0に近づく。なお、本研究では事前解析より L_R に係数 β をつけて、より強く再構築誤差の減少が進むように制約を加えた。本研究では、予備解析より $\beta = 5000$ とする。式(13)において本研究のように2個の確率分布がともに正規分布の場合、次式のように計算できることが知られている。¹⁰⁾

$$D_{KL}[N(\boldsymbol{\mu}, \boldsymbol{\Sigma}) \| N(\mathbf{0}, \mathbf{I})] = -\frac{1}{2} \sum_{s=1}^G \left\{ \log(\sigma_s^{(m)})^2 + 1 - (\sigma_s^{(m)})^2 - (\mu_s^{(m)})^2 \right\} \quad (14)$$

ここで G は \mathbf{z} の次元数、 $\sigma_s^{(m)}$ はデータ m に対する共分散行列の s 番目の対角項であり、 $\mu_s^{(m)}$ は平均ベクトルの

s 番目の成分である。

なお本研究では特徴抽出手法として VAE を利用したが、例えば主成分分析など他の特徴抽出手法の利用も考えられる。この点については今後の課題とする。

4.2. VAEの学習の結果と適切な特徴量の次元

VAEの学習は、予備解析で最も再構成精度が高かった表4のネットワーク構成で行った。表4に示す、Conv2D層は画像認識用CNN¹¹⁾で一般的に採用されている畳み込み層を表している。Flatten層とReshape層は、従来のDense層とConvolution層の間でデータを変換し、Flatten層は全結合層からのデータを1次元配列(Dense層)に変換する。Reshape層は逆にDense層を3次元配列(Conv2D層)に変換する。

特徴量 \mathbf{z} の次元 n_z については、 $n_z = 1, 2, \dots, 5$ と変えて学習を行った。VAEにモード画像 \mathbf{C} を入力し、出力されたモード画像 \mathbf{C}' の再構築精度を決定係数 R_c^2 で表わした表を表5に示す。 R_c^2 は次式より算出した。

$$R_c^2 = 1 - \frac{\sum_{k=1}^M (C_k - C'_k)^2}{\sum_{k=1}^M (C_k - \mu_C)^2} \quad (15)$$

ここで C_k, C'_k は \mathbf{C}, \mathbf{C}' の k 番目の各成分、 μ_C は \mathbf{C} の平均値を示す。表より、 $n_z = 1$ のケースでも $R_c^2 = 0.971$ と十分な精度であることがわかる。また、 n_z の増加に伴い R_c^2 は大きくなり、 $n_z = 3$ 以上で R_c^2 は0.989と一定になることが確認できる。本研究のデータセットでは \mathbf{z} が1次元でも十分、特徴量を表現できると判断し、以後 $n_z = 1$ の結果を中心に議論を進める。

表4 VAEの構成

	層の種類	出力サイズ
エンコーダ	Input	(50,50,3)
	Conv2D	(48,48,16)
	Conv2D	(24,24,32)
	Conv2D	(12,12,64)
	Flatten	(9216)
	Dense	(128)
特徴量	Dense ($\boldsymbol{\mu}, \boldsymbol{\sigma}^2$)	(2)
	Dense (\mathbf{z})	(n_z)
デコーダ	Dense	(128)
	Dense	(9216)
	Reshape	(12,12,64)
	Conv2D	(24,24,32)
	Conv2D	(48,48,16)
	Output	(50,50,3)

表5 特徴量の次元数毎のVAEの再構築精度

n_z	1	2	3	4	5
R_c^2	0.971	0.984	0.989	0.989	0.989

5. VAE を利用した振動モードの分析

5.1. 特徴量を用いた振動モードの分類

4章で学習した VAE のデコーダに、 z の発生範囲内の任意の値^(註1)を入力することで得られるモード画像を図 6 に示す。図より、 z が $0.0 \sim -3.0$ の範囲では大きく水色と黄緑色の 2 色によるモード図が得られることがわかる。また、 $z = -1.0$ を境に上下の画像の縁の灰色部分（図中丸印）の幅が大きくなる傾向がある。一方で、 $z = 1.0$ 付近では 4 個の色が縞状に並んでいる傾向があり、 $z = 3.0$ では縞が 6 個に増えることがわかる。3 章で示したように色は振動モードの XYZ 成分に対応するため、色が切り替わる場所は振動モードの節になると考えられる。このため、 z が 0 以下の範囲ではアーチ方向に 2 波、 $z = 1.0$ 付近では 4 波、 $z = 3.0$ では 6 波の振動モードが得られることになる。

ここで、10000 個の解析モデルの主モード画像を図 6 に示すように定性的に 4 個の Group に分類する。各 Group に属する代表的な振動モードを図 7 に示す。図 7 より、各 Group でモードの半波数が異なり、Group1, 2 は半波数 2、Group3 は半波数 4、Group4 は半波数 6 であることが確認できる。Group1, 2 はともに半波数が 2 であるが、Group1 では桁境界部付近（図 7(a)赤丸）の鉛直成分が小さいのに対し、Group2 は桁方向境界部（図 7(b)赤丸）の鉛直成分が大きい。各 Group のデータ数は、

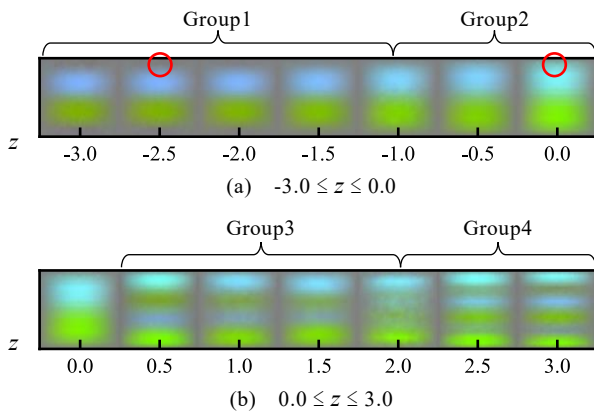


図 6 任意の特徴量 z に対するモード画像

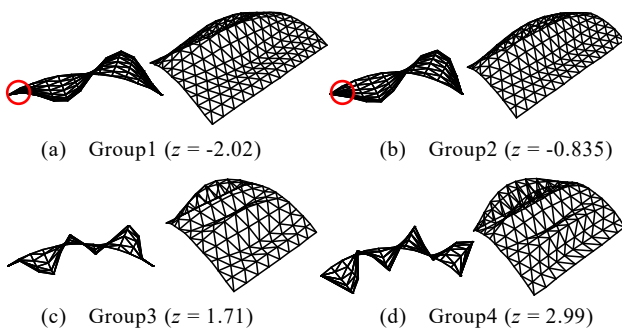


図 7 各 Group の代表的なモード形状

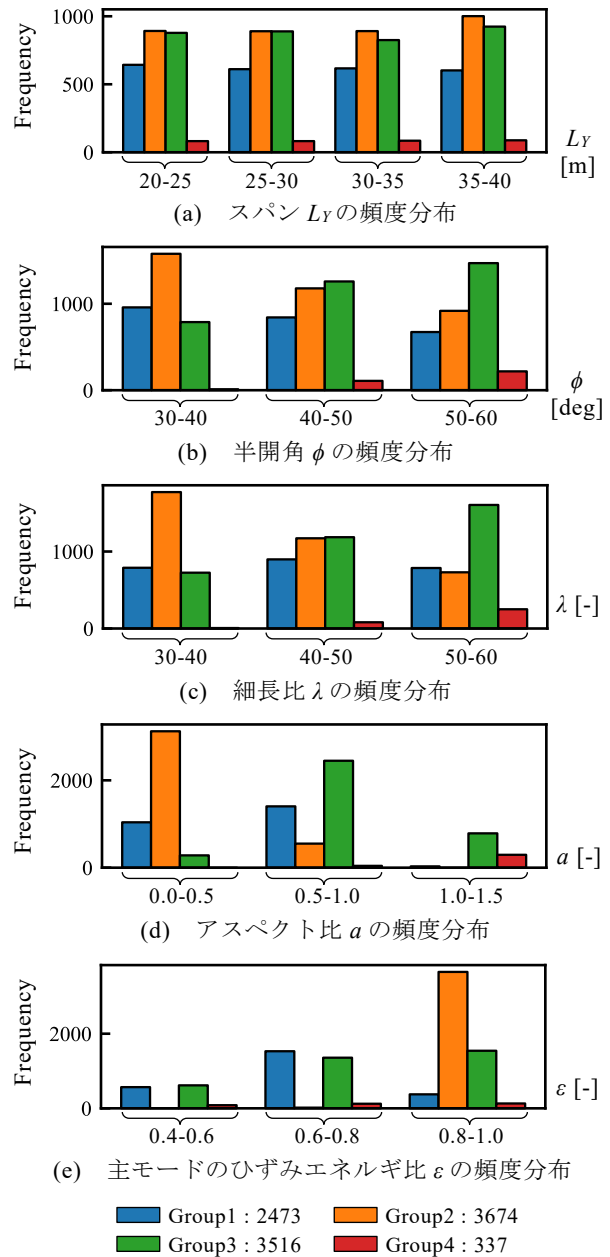


図 8 各 Group のパラメータの頻度分布

Group1 が 2473 個、Group2 が 3674 個、Group3 が 3516 個、Group4 が 337 個である。

5.2. 特徴量とシェルの形状パラメータの関係

10000 個のデータセットにおける各解析モデルのモード画像から抽出した z と解析モデルのパラメータを基に解析パラメータと Group の関係性を分析する。各 Group のスパン L_y 、半開角 ϕ 、細長比 λ 、アスペクト比 a 、主モードのひずみエネルギー比 ε の分布を図 8 に示す。図 8 の横軸は各パラメータ、縦軸は横軸の目盛り間の各 Group のデータの頻度を表す。ここでアスペクト比 a は式(16)で計算したものであり、 a が小さいほどアーチ方向に比べて桁方向のスパンが大きいシェルを表す。

$$a = \sqrt{3n_y} / 2n_x \quad (16)$$

図 8 より、まず、Group4 はアスペクト比が 1.0~1.5 の範囲の桁方向に短いシェルでのみ発生する振動モードであり、全体的に数が少ないことがわかる。Group1, 2, 3 は本研究のパラメータの範囲内では多く分布するが、その分布にはスパンの影響がないことが図 8(a)よりわかる。Group2 は半波数が 2 の振動モードで、ひずみエネルギー比が 0.8 より大きい範囲に集中する傾向がある。また、比較的小開角が小さく、細長比が小さい形状で発生する傾向がある。Group1 は Group2 と似た形状ではあるが、Group2 よりひずみエネルギー比が小さい傾向がある。Group3 はアスペクト比が 1.0 前後に多く存在し、比較的小開角が大きい形状に現れる傾向がある。

6. まとめ

本研究では周辺ピン支持の単層円筒形状を対象として、振動モードの特徴量を抽出する手法を提案した。提案手法はまず、振動モードを画像データに変換し、その後 VAE を利用して次元削減を行うものである。また、抽出した特徴量の利用例として、円筒ラチスシェルの振動モードと構造パラメータの関係性を分析した。得られた知見を以下に示す。

- 1) 本研究で提案した振動モードを画像化する手法は、円筒ラチスシェルの半開角 ϕ が 30 ~ 80 deg の範囲において、高い精度で振動モードとモード画像間のデータ変換を行うことができる。
- 2) VAE を用いてモード画像の特徴抽出を行った結果、円筒ラチスシェルの振動モードの特徴量が 1 次元で十分な精度を持つことがわかった。次元数を増やすことで精度の向上が見られるものの 3 次元以上のケースでは一定値を示した。
- 3) 円筒ラチスシェルのひずみエネルギー比が最も大きい振動モードは特徴量の抽出より 4 個の場合に分類できることがわかった。具体的には①アーチ方向半波数が 2 で、境界部の鉛直振動モード成分が大きい場合、②アーチ方向半波数が 2 で、境界部の鉛直振動モード成分が小さい場合、③半波数が 4 の場合、④半波数が 6 の場合である。
- 4) 半開角が小さく、細長比が小さく、桁方向の長さが長い円筒ラチスシェルは半波数が 2 の振動モードが卓越する傾向が確認できる。一方で、ライズがやや高くなる場合や、細長比が大きくなると、円筒ラチスシェルは主モードのひずみエネルギーが小さくなる傾向があり、また、シェルの桁方向の長さの大小により複雑な振動モード形状が発生する場合があることがわかった。

今後は抽出した特徴量 z を用いて振動モードを推定す

る手法について検討を進める。 z を推定することができれば、 z から振動モードに変換することができ、構造物の固有周期の推定や文献⁴⁾を参考に地震荷重の算定に活用することができる。加えて、本論文で対象とした矩形平面のモデルではなく、他の平面形状のモデルでの利用も今後検討が必要である。

謝辞

本研究は日本鉄鋼連盟 鋼構造研究・教育助成事業の助成を受けたものである。ここに記して謝意を表す。

【参考文献】

- 1) 日本建築学会：ラチスシェル屋根構造設計指針, 2016.11
- 2) 山田聖志, 松本幸大, 加藤史郎：屋根型単層円筒ラチスの地震動による応答性状と静的地震荷重に関する考察, 鋼構造論文集, 第 11 巻 41 号, pp.33-46, 2004.3
- 3) 竹内徹, 小河利行, 山形智香, 熊谷知彦：支持架構付き屋根型円筒ラチスシェルの地震応答評価, 日本建築学会構造系論文集, 第 596 号, pp.57-64, 2005.10
- 4) Y. Takiuchi, S. Kato, S. Nakazawa, Y. Higashiyama, Statically equivalent seismic loads based on two-mode-based approach for single layer reticulated shells, *Engineering Structures*, Vol.260, 114242, 2022
- 5) R. Zhang, Y. Liu, H. Sun, Physics-informed multi-LSTM networks for metamodeling of nonlinear structures, *Engineering Structures*, Vol.369, 113226, 2020
- 6) B.K. Oh, Y. Park, H.S. Park, Seismic response prediction method for building structures using convolutional neural network, *Struct. Contr. Health. Monit.*, Vol.27, Issue5, e2519, 2020
- 7) K. Hayashi, M. Ohsaki, Reinforcement Learning and Graph Embedding for Binary Truss Topology Optimization Under Stress and Displacement Constraints, *Front. Built Environ.*, 2022
- 8) 加藤史郎, 中澤祥二, 神戸健彰, 柳澤利昌：等分布荷重を受ける屋根型単層円筒ラチスシェルの耐力評価法に関する研究単純支持およびピン支持に関する検討, 日本建築学会構造系論文集, 第 78 巻 692 号, pp.1777-1786, 2013.10
- 9) 笠井和彦, 伊藤浩資, 渡辺厚：等価線形化による一質点弾塑性構造の最大応答予測法, 日本建築学会構造系論文集, Vol.68, No.571, pp.53-62, 2003.9
- 10) Kingma DP, Welling M. Auto-Encoding Variational Bayes 2013. <https://doi.org/10.48550/arxiv.1312.6114>.
- 11) Y. LeCun, L. Bottou, Y. Bengio, P. Haffner, Gradient-based learning applied to document recognition, *Proc. of the IEEE*, Vol.86, Issue.11, pp.2278-2323, 1998.11

注 1)

$n_z = 1$ としたときの z の頻度分布を図 9 に示す。図より z は概ね ± 3 の範囲に分布している。




図 9 各 Group の特徴量 z の頻度分布