

ニューラルネットワークによるサロゲートモデルを用いた構造最適化 2次元橋梁モデルの曲げひずみエネルギー最小化

Structural Optimization Using Surrogate Models with Neural Networks Bending strain energy minimization for 2D bridge models

○久住 呂 大志^{*1}, 横須賀 洋平^{*2}, 本間 俊雄^{*3}
Taishi KUJURO^{*1}, Yohei YOKOSUKA^{*2}, Toshio HONMA^{*3}

*1 鹿児島大学大学院理工学研究科工学専攻建築学プログラム 大学院生

Graduate Student, Graduate School of Science and Engineering, Kagoshima University

*2 鹿児島大学大学院理工学研究科工学専攻建築学プログラム 准教授・博士(情報科学)

Associate Professor, Graduate School of Science and Engineering, Kagoshima University, Ph.D.

*3 鹿児島大学 名誉教授・工学博士

Emeritus Professor, Kagoshima University, Dr.Eng.

キーワード：ニューラルネットワーク、サロゲートモデル、構造最適化

Keywords: Neural network, surrogate model, structural optimization

1. はじめに

近年最適化や機械学習の技術進展により、計算機による意思決定プロセスが身近な存在となっている。建築構造物の設計において、構造部材の総重量や部材配置、設計形状の最適化問題は、これまでに多数の研究報告がある¹⁾。建築構造の形態創生における解探索手法には発見的な手法が有用な手法として適用される²⁾が、これらの手法は目的関数の微分計算が必要ではないため、汎用性が高い手法として知られている。しかし、最適化問題の高次元化に伴う探索性能の低下や計算コストの増加などの問題が存在している。そこで著者らは、サロゲートモデルにニューラルネットワークを採用し、最適化問題に組み込むことで計算コストを削減する最適化手法の提案を行った³⁾。建築構造の最適化問題への適用例として、SVMや決定木などの手法を用いた最適ブレース配置の研究が報告されている⁴⁾が、最適化問題に対する提案手法の適用範囲や、その近似精度に関する検討が必要である。

本稿では、2次元橋梁モデルの曲げひずみエネルギー最小化問題を扱い、本手法により最適化問題を解くことで、その最適解や解空間の近似精度を検証することを目的とする。まず、2次元橋梁モデルについて、各応力の検定比を教師信号としたニューラルネットワークの学習を行い、サロゲートモデルを構築する。そして、最適化プロセスにおいて有限要素解析を行わずに、サロゲートモデルによって目的関数を評価し探索を行い、その近似精度と計算コストの数値結果により、本手法の妥当性を示す。

2. ニューラルネットワーク(Neural Network)

本稿では、サロゲートモデルの構築にニューラルネッ

トワーク(以下 NN)を採用する。NNは脳機能に見られるいくつかの特性に類似した数理的モデルであり、その概要や定式化については文献⁵⁾を参照されたい。また、NNの学習において、過学習という訓練データに対しては適合できているが、未学習の未知データに対して適合できていないという問題がしばしば発生する。そこで過学習を防止する手法として、ドロップアウトという手法が提案されている。これは学習に用いるユニットを制限する手法であり、学習中にドロップアウトさせるユニットをランダムに交代させることで、一種のアンサンブル学習を行うことが可能になる。本稿ではドロップアウトの有無による、近似解の比較を行っている。また学習時、未知データの損失関数値に改善が見られない、もしくは悪化し続ける場合、その時点で学習を早期終了する。

3. 人工蜂コロニーアルゴリズム(Artificial Bee Colony)

本稿では構造最適化の解探索手法に、人工蜂コロニーアルゴリズム(以下 ABC)を用いる。ABCはミツバチの採餌行動に基づいて提案された最適化アルゴリズムである。本稿ではその中でも解探索の向上を目的として提案された改良型 ABC⁶⁾を採用する。以下にその計算手順を示す。

step0) 計算準備

反復回数カウンタ k を初期化し、 $k = 1$ とする。また、適合度上位の探索点数 α 、解への収束状況パラメータ dr 、許容限界値 f_{bound} 、 f_{bound} に対する制度値 $f_{accuracy}$ 、総反復回数 T_{max} 、「段階 1」の最低反復回数 T_{1min} を設定する。

step1) 初期食糧源決定

食糧源を設計変数空間にランダムに配置する。また、初期状態における最良解(best⁰⁾を決定し、全食糧源の平




図1 Model A (m)




図2 目的関数値の遷移 ABC-FEM



図3.2 解形状 2 試行目 $f = 7.06.E-02$

表1 ABC パラメータ

| | |
|---------------------|-------------------------|
| <i>employed bee</i> | 200 |
| <i>onlooker bee</i> | 200 |
| α | 60 |
| dr | 0.9 |
| f_{bound} | 0.0 |
| $f_{accuracy}$ | 1.0×10^{-16} |
| $T1_{min}$ | 500 |
| T_{max} | 50000(FEM) 10000(NN) |

表2 NN パラメータ

| | |
|-----------------|--------------|
| ユニット構成 | 9-200-200-45 |
| 活性化関数 | Sigmoid |
| 学習データ数 | 100000 |
| epoch | 最大 10000 |
| バッチサイズ | 100 |
| 早期終了判定の epoch 数 | 300 |



図3.1 解形状 1 試行目 $f = 5.57.E-02$



図3.3 解形状 3 試行目 $f = 6.25.E-02$

均評価値 f_{min} を算出する。食糧源一つ $\mathbf{X}^i (i = 1, 2, \dots, n)$ に対して一匹 $eb \mathbf{X}^i$ を割り当てる。

step2) *employed bee* による探索

各食糧源 \mathbf{X}^i の目的関数値 $f(\mathbf{X}^i)$ から、各食糧源の適合度 fit_i^k を次式により計算する。

$$fit_i^k = \begin{cases} \frac{1}{f(\mathbf{X}^i) - f_{bound}}, & f(\mathbf{X}^i) - f_{bound} \geq f_{accuracy} \\ \frac{1}{f_{accuracy}}, & f(\mathbf{X}^i) - f_{bound} < f_{accuracy} \end{cases} \quad (1.1)$$

全食糧源 \mathbf{X}^i に対して、それらの更新候補点を次式により計算する。

$$eb \mathbf{X}_{ih}^k = \mathbf{X}_{ih}^k + \phi(\mathbf{X}_{ih}^k - \mathbf{X}_{ih}^{k-1}), \quad eb \mathbf{X}_{ic}^k = \mathbf{X}_{ic}^k \quad (1.2)$$

ここで、下添字 h は探索点ごとにランダム選択された一つ的设计変数番号を表し、下添字 z は選択された番号以外の设计変数番号を表す。また、 ϕ は $[-1, 1]$ の一様乱数であり、下添字 j は、 $(k \geq T1_{min}) \& (f_{judge} \geq dr)$ の場合は食糧源ごとに食糧源番号 i 以外で相対価値確率 P^k に基づくルーレット選択により選択された参照点番号を表し、そうでない場合は食糧源番号 i 以外で適合度上位 α の食糧源中からランダム選択された参照点番号を表す。また、反復回数 $k \geq T1_{min}$ において、 $f_{judge} < dr$ であれば式(1.3)によって f_{judge} の値を更新する。

$$f_{judge} = \frac{f_{init} - f(\mathbf{best}^k)}{f_{init} - f_{bound}} \quad (1.3)$$

$$P^k = fit_i^k / \sum_{i=1}^n fit_i^k \quad (1.4)$$

この更新値が $f_{judge} \geq dr$ となれば、適合度を用いて各食糧源 \mathbf{X}^i の相対価値確率 P^k を次式(1.4)より計算する。上記のように更新候補点を計算し、 $f(eb \mathbf{X}^i) \leq f(\mathbf{X}^{i-1})$ ならば $\mathbf{X}^i = eb \mathbf{X}^i$ を記憶し、そうでなければ \mathbf{X}^{i-1} を保持する。

step3) *onlooker bee* による探索

onlooker bee の探索カウンタ l を初期化する。 $(k \geq T1_{min}) \& (f_{judge} \geq dr)$ の場合は、相対価値確率 P^k に基づくルーレット選択により一つの食糧源 \mathbf{X}_{ic}^k を選択し、そうでない場合は、適合度の高い上位 α の食糧源中からランダムに一つの食糧源 \mathbf{X}_{ic}^k を選択する。ここで、下添字 ic は選択された食糧源番号を表す。そして、選択された食糧源 \mathbf{X}_{ic}^k についてのみ、式(1.2)と同様に更新候補点 $ob \mathbf{X}_{ic}^k$ を生成し、この食糧源のみ更新する。 l が *onlooker bee* 数でなければ、 $l = l + 1$ として、更新候補点 $ob \mathbf{X}_{ic}^k$ を生成し、解を更新する。

step4) 最良探索個体の更新

最良解(\mathbf{best}^k)を更新する。

以上の step2-4 を指定した反復回数だけ繰り返し、最も適合度が高い個体を解個体とする。以上が改良型 ABC の計算フローである。

4. 2次元橋梁モデルの曲げひずみエネルギー最小化

4.1 最適化定式化

数値実験例として、節点座標移動量を設計変数とした2次元橋梁モデルの曲げひずみエネルギー最小化を扱う。解析モデルの初期形状は図1に示す Model-A(節点数:22、要素数:29)であり、有限要素解析には梁要素を用いる。最適化の定式化を以下に示す。

$$\text{Find} \quad \mathbf{R} \quad (2.1)$$

$$\text{to minimize} \quad f(\mathbf{R}) = \sum_{k=0}^n V_k (M_{ki}^T \mathbf{K}_{ki} + M_{kj}^T \mathbf{K}_{kj}) \quad (2.2)$$

$$\text{subject to} \quad \sigma^L \leq \sigma_k(\mathbf{R}) \leq \sigma^U \quad (2.3)$$

$$R^L \leq \mathbf{R} \leq R^U \quad (2.4)$$

ここで、 \mathbf{R} : 節点座標移動量ベクトル、 V_k : k 部材体積、 $M_{ki,kj}$: k 部材 i 端 j 端曲げモーメント、 $\mathbf{K}_{ki,kj}$: k 部材 i 端




図 4.1 損失関数値の遷移 ドロップアウト無



図 5.1 解形状 NN1
 $f = 5.47.E-02$ (8.51.E-01)




図 4.2 目的関数値の遷移 ABC-NN ドロップアウト無



図 5.2 解形状 NN2
 $f = 4.39.E-02$ (2.68.E-01)



図 5.3 解形状 NN3
 $f = 7.30.E-02$ (8.72.E-01)




図 6.1 損失関数値の遷移 ドロップアウト有



図 7.1 解形状 NN1
 $f = 3.21.E+00$ (4.52.E-01)




図 6.2 目的関数値の遷移 ABC-NN ドロップアウト有



図 7.2 解形状 NN2
 $f = 2.89.E+00$ (4.31.E-01)



図 7.3 解形状 NN3
 $f = 3.17.E+00$ (3.21.E-01)

j 端曲率、 σ_k : k 部材応力度である。応力制約は短期許容応力度を用い、座屈を考慮した鋼構造設計基準式を用いる。 \mathbf{R} は Y 座標移動量 : $R^L = -30\text{m}$, $R^U = 30\text{m}$ 、 X 座標移動量 : $R^L = -6.5\text{m}$, $R^U = 6.5\text{m}$ の側面制約を与える。荷重条件は分布荷重と自重を考慮し、材料条件は断面一定の角形鋼管を想定、弾性係数 $E = 2.05 \times 10^8 \text{kN/m}^2$ 、質量密度 $\rho = 78.5 \text{kN/m}^3$ と設定する。また、設計変数は対称性を考慮する。

次に NN について、入力値は設計変数、教師信号は各応力を許容応力度で除した検定比とする。また NN を用いた最適化の際、目的関数値の算出は曲げモーメントの推定値から曲率を計算し関数値の算出を行う。

ABC, NN の計算パラメータは表 1,2 に示す値を採用し、NN の学習はドロップアウトを考慮して 3 回ずつ行う。最適化は有限要素解析、各 NN を用いて 3 試行の数値実験を行う。最適化の反復回数は各手法の目的関数値の遷移を考慮しそれぞれ決定しており、NN の学習における学習データは、設計変数空間に乱数を用いて発生させたランダムデータ(50000)と、その内応力制約を満足している許容解データ(50000)の計 100000 データを学習データとして用いる。これは、本最適化問題の許容解比が約 0.3%程度と非常に許容解の割合が低いことから、学習データの許容解データ割合を増やし、最適化の近似精度を向上させることを目的としている。

4.2 数値結果と考察

数値結果として図 2,4,6 に目的関数値と損失関数値の

遷移、図 3,5,7 に解形状および目的関数値を示す。数値情報は f : 目的関数値、(NN については推定値、かつこ内が解析値)、iteration number : 反復回数、loss : 損失関数値、epoch : 学習回数である。また、図や表に示す ABC-FEM は有限要素解析、ABC-NN は NN による最適化の結果を表している。

ABC-FEM の結果について、図 2 に示す目的関数値の遷移より、1 試行目は十分な収束が見られ、その他も 50000 回時点で概ね収束していることが判る。図 3 に示す解形状より、試行によって設計変数、目的関数値に微小な差があるが、いずれの試行も得られた最適解はアーチ型の解形状であることを確認した。

ABC-NN の結果について、各 NN について 1 試行目の結果を抜粋して示す。図 4,6 に示す損失関数値、目的関数値(推定値)の遷移より、NN の学習は両手法とも早期終了判定を満たしており、目的関数値はいずれも十分に収束している。また、目的関数値(推定値)は学習手法によりオーダーに差が見られ、ドロップアウト無の方が小さな値をとる結果となったが、解析値ではその傾向は見られない。次に図 5,7 に示す解形状、目的関数値より、ドロップアウト無の場合 NN によって得られる最適解形状が異なり、アーチ型、サスペンション型の 2 種の解形状が得られた。一方で、ドロップアウト有の場合、NN によらず得られた解形状はサスペンション型の形状であった。ドロップアウト無では、ABC-FEM と同様のアーチ型の解形状が得られたが目的関数値(解析値)には差があ




図 8.1 各クラスターの平均形状及び割合 ABC-FEM (1 試行目)




図 8.2 各クラスターの平均形状及び割合 ABC-NN (ドロップアウト有 NN1 1 試行目)

ることが判り、サスペンション型の方が目的関数値は小さい。ドロップアウト無の場合、NN によって最適解形状が異なることは、解探索の安定性に欠けると考えられる。しかし、ドロップアウトを用いることで、NN によらず同様の最適解を得ることができ、解探索の安定性の観点から有意であるといえる。しかし、最適解のみを比較すると、アーチ型とサスペンション型とで最適解形状が大きく異なる結果となった。

4.3 計算コスト

表 3 に各手法の 1 試行計算コストを示す。ABC-FEM の反復回数 10000 回を基準とし、ABC-NN は学習データの作成及び学習のコストを考慮する。数値結果より、NN の学習コストを含めても約 50%であり、計算コストの優位性を示している。

5. 解空間の近似精度

前章で ABC-FEM, NN で最適解の形状が大きく異なる結果を示した。このように、NN の学習モデル及び学習方法で試行ごとに異なった最適解が得られてしまう。そこで、解空間全体の近似精度を検証するために、探索終了後の探索個体群の比較を行う。

5.1 クラスタリングによる解空間の比較

比較方法として、ABC-FEM, NN の探索終了後の探索個体群 200 個体について、*k*-means 法を用いてクラスタリングを行い、その結果より解空間を比較検証する。また、*k*-means 法のクラスタ数は 7 とする。数値結果として、図 8 に各クラスターの平均形状及び探索個体全体における割合を示す。ABC-FEM は 1 試行目、ABC-NN は NN1 (ドロップアウト有) の 1 試行目の探索個体群を対象にクラスタリングを行った結果を示している。

5.2 数値結果と考察

図 8.1 に示す ABC-FEM の結果より、各クラスターの平均形状はアーチ型以外にサスペンション型の形状を多く含むことが判った。各クラスターで割合は異なるが、クラスターごとに形状に差があることが確認できる。次に図 8.2 に示す ABC-NN の結果より、各クラスターの割合に差はあるが、アーチ型の形状も含むことが判り、ABC-FEM と概ね同様の傾向を示していた。以上の結果から、最適解形状は ABC-FEM, NN で異なるが、探索個体群全体は同様の傾向を示しており、解空間全体の近似ができてい

表 3 1 試行計算コスト(%)

| ABC-FEM | NN 学習 | ABC-NN | SUM |
|---------|-------|--------|-------|
| 100.00 | 24.83 | 25.33 | 50.16 |

と考えられる。各クラスターの割合が異なることや、最適解の目的関数値に差があることは、NN の近似精度の限度が主要要因であると考えられるが、ドロップアウト有の場合、最適化の解探索が安定し、解空間が適度に汎化性能を保ちつつ近似されている。このことは、最適化問題の設計変数を同定する本手法において、元の問題の極値の位置が再現できていれば有意であると考えられる。

従って、解空間全体の近似ができていたり、計算コストの面で優位であることから、効率的に解空間の把握を行う方法として、本手法は有用であると考えられる。

6. まとめ

本稿では、2 次元橋梁モデルの曲げひずみエネルギー最小化問題を、NN によるサロゲートモデルを用いて最適化を行った。NN の学習時ドロップアウトを用いることは、解探索の安定性や汎化性能の観点で有意であるといえる。また、効率的に解空間全体を把握する方法としても本手法は有用であることを示した。今後の展望として、位相を設計変数として扱う鋼構造骨組みのブレース配置問題などへの適用を検討する。

謝辞

本研究は、JST, CREST, JPMJCR1911 の支援を受けた。

【参考文献】

- 1) 三井和男, 大崎純, 大森博司, 田川浩, 本間俊雄: 発見的最適化手法による構造フォルムとシステム計算工学シリーズ 4, コロナ社, 2004
- 2) 本間俊雄, 野瑞憲太: 解の多様性を考慮した遺伝的アルゴリズムによる構造形態の創生, 日本建築学会構造系論文集, 614, pp.35-43, 2007
- 3) 久住呂大志, 横須賀洋平, 本間俊雄: ニューラルネットワークによるサロゲートモデルを用いた構造最適化-2 次元橋梁モデルの断面・形状最適化-, 第 15 回コロキウム構造形態の解析と創生 2020, pp.41-46, 2020
- 4) 田村拓也, 大崎純, 高木次郎: 機械学習を用いた鋼構造骨組みのブレース配置の分析, 日本建築学会近畿支部研究発表会, 57, pp.83-84, 2017
- 5) 宇谷明秀, 西本雅明, 山本尚生: 高次元工学設計問題のための最適化手法, 知能と情報(日本知能情報フェジィ学会誌), Vol24, No3, pp.791-802, 2012