

鋼構造骨組のサロゲートモデルによる最小重量設計

応力と層間変形角の制約による検定

Minimum weight design by surrogate model of steel structural frames

examination with stress and interlaminar deformation angle constraints

○石本 大和*¹, 横須賀 洋平*²

Yamato ISHIMOTO*¹, Yohei YOKOSUKA*²

*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

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

キーワード：鋼構造骨組；最小重量設計；遺伝的アルゴリズム；ニューラルネットワーク；

Keywords: steel structural frames; minimum weight design; genetic algorithm; neural network.

1. はじめに

近年、最適化や機械学習のような計算機を用いた意思決定プロセスによる設計例が増えつつある。建築構造の設計において、構造部材の総重量や部材配置、設計形状等の最適化は、これまでに数多くの研究が報告されている¹⁾。しかし、最適化を大規模建築物に適用すると計算コストが増大する傾向にある。そこで、最適化問題に機械学習やサロゲートモデルを適用することにより、計算コストを削減しつつ近似的な最適解の効率的な獲得を行う研究が行われている²⁾。サロゲートモデルは、数値解析を実行する代わりに応答や目的関数値を近似したモデルのことである。

本研究では、サロゲートモデルとしてニューラルネットワーク(Neural Network : NN)、最適化手法に遺伝的アルゴリズム(Genetic Algorithm : GA)を採用し、効率的に最小重量問題を解くことを目的とする。本稿では、二次元鋼構造骨組を対象とし、ブレース配置と部材断面の同時最適化問題とする。NN は制約条件の検定結果を判断する分類問題を扱ったモデルを構築する。さらに提案手法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

2. 機械学習と構造最適化

機械学習は教師あり学習、教師なし学習と強化学習の3つに大別される。さらに、教師あり学習は、数値を予測する回帰問題と、所属するクラスを分類する分類問題が存在する。機械学習では一度機械学習モデルが構築されれば、高速に推定値や予測ラベルを出力することができる。一方、最適化問題においては、数理計画法と発見的手法に大別され、発見的手法は目的関数値の微分計算が不要で、かつ大域的最適解が得られるが、多点探索による有限要素解析を実行する場合には、膨大な計算コストを必要とする。

機械学習と最適化を組み合わせた構造最適化では、教師

あり学習の回帰問題を扱うことが多い。しかし、NN の学習では、目的関数値に複数の応答を含み、出力値の数が膨大である場合や、出力値のばらつきが大きい場合は推定精度が悪化する可能性がある。一方で、重量を目的関数とする最小重量設計では、応答が目的関数に含まれる必要がなく制約条件の検定結果のみで最適化問題を解くことができる。本稿では、部材応力や層間変形角の制約条件の検定結果を判断する分類器としてNNを用いたサロゲートモデルを構築する。以下に提案手法の計算フローを示す。

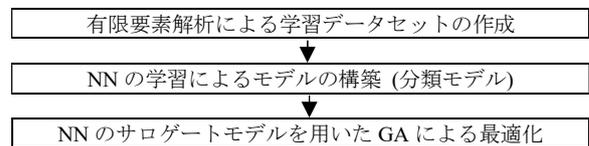


図1 提案の計算フロー

3. 最適化問題の概要

3.1 最適化の定式化

解析モデルは柱・ブレース部材が角型鋼管、梁部材がH形鋼からなる骨組架構として、図2に示すスパン9.6m、階高4m(一部5m)を有する最大8層3スパンの鋼構造骨組である。層数を3層から8層まで変化させ、それぞれの規模について最適化を行う。柱・梁部材は表1のものを用い各層に使用する部材は規模ごとに表2に示す部材番号のものとする。これらは、長期許容応力度設計を満足するように設定されている。ブレース部材は表3,4に示す部材リストから選択される。ブレース部材が存在しない断面をリストに追加することで、配置と断面の同時最適化を実施する。また、ブレース部材の各リストの選択率は、同時最適化を考慮し、リスト番号1:50%、リスト番号2-8:7.143%と重み付けを行い、対象形状を得るために対象条件を考慮する。モデルの解析には有限要素解析を用い、最適化の定式化は以下のようなになる。

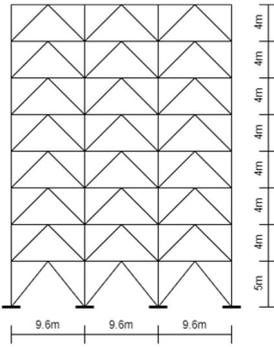


図2 解析モデル

表5 配置パターンとデータ数

story	Pattern	Data
3	64	10000
4	265	10000
5	1024	20000
6	4096	30000
7	16384	30000
8	65536	50000

表1 柱梁部材断面

List number	Section	A(mm ²)	
1	column	□-400-400-19	27100
	beam	H-400-200-9-19	11000
2	column	□-450-450-19	30900
	beam	H-450-200-9-19	11450
3	column	□-550-550-19	34700
	beam	H-550-200-9-19	12350

表2 使用部材番号

Max Story	story							
	1	2	3	4	5	6	7	8
3	2	2	1					
4	2	2	1	1				
5	3	3	2	2	1			
6	3	3	2	2	1	1		
7	3	3	2	2	1	1	1	
8	3	3	2	2	2	1	1	1

表3 ブレース部材断面(3-7層)

Brace	Section	A(mm ²)
List number		
1	□-0-0-0	0
2	□-125-125-6	2763
3	□-150-150-6	3363
4	□-175-175-9	5767
5	□-200-200-9	6667
6	□-200-200-12	8653
7	□-250-250-12	11050
8	□-300-300-12	13450

表4 ブレース部材断面(8層)

Brace	Section	A(mm ²)
List number		
1	□-0-0-0	0
2	□-175-175-9	5767
3	□-200-200-9	6667
4	□-200-200-12	8653
5	□-250-250-12	11050
6	□-300-300-12	13450
7	□-350-350-16	20720
8	□-400-400-16	23920

表6 NNパラメータ

	model-R	model-L
ユニット	138-1500-1500-296	138-1500-1500-296
Epoch	2000	2000
Batch size	1024	1024
損失関数	平均二乗誤差	交差エントロピー

表7 学習終了時の正答率の平均

model-R	model-L
99.4%	99.7%

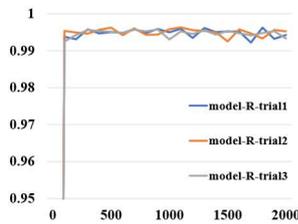


図3 model-Rの正答率遷移

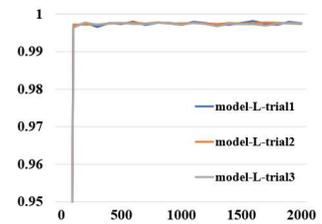


図4 model-Lの正答率遷移

$$\text{Find } \mathbf{A}^b \quad (1)$$

$$\text{to min. } f(\mathbf{A}^b) = \mathbf{L}^T \mathbf{A} \quad (2)$$

$$\text{subject to } \sigma^L / \nu \leq \sigma_i \leq \sigma^U / \nu \quad (3)$$

$$\theta_k \leq \theta^U$$

$$A^L \leq A^b \leq A^U$$

ここで、 \mathbf{A}^b :ブレース部材の断面リスト番号、 \mathbf{L} :部材長ベクトル、 \mathbf{A} :断面積ベクトル、 $\nu (=1.5)$:安全率、 σ_i : i 部材の圧縮・引張・せん断・曲げ応力度、 θ_k : k 層の層間変形角、 $\sigma^L, \sigma^U, \theta^U, A^L, A^U$:側面制約であり、 $A^L=1, A^U=8, \theta^U=1/200$ である。応力制約は短期許容応力度とし、圧縮応力度については、細長比により決定される座屈を考慮した鋼構造設計基準式を用いる。外力として、地震力を A_i 分布に従って作用させる。設計床荷重は各階とも 7.84kN/m^2 であり、桁行方向は 6.4m を想定する。地震力算定の条件は第二種地盤 $Z=1.0$ 、振動特性係数 $R=1.0$ 、標準せん断力係数 $C_0=0.2$ として地震層せん断力から算定した水平荷重を負担面積に応じて各節点に作用させる。

3.2 サロゲートモデル

NNの入力値 x を設計変数とし、3-8層分のデータを同時に学習し、同一のNNにより各規模での最適化を実施する。学習データセットは層数に応じたブレース配置パターン

を考慮して、表5に示すデータ数に従い作成する。設計変数はブレース配置およびリスト化した断面を決定するためのカテゴリカルな離散変数であり、リスト番号と部材の断面性能に直接的な関係がないため、ダミー変数を用いて $\{0,1\}$ の2値の配列に変換する。

4. 回帰モデルと分類モデルの比較

4.1 作成するモデル

回帰モデルを model-R、分類モデルを model-L とし、各々学習データの教師信号を $\mathbf{t}_R, \mathbf{t}_L$ とし、次式で定義する。

$$\mathbf{t}_R = \left[\frac{\sigma_i}{f_i}, \frac{\theta_k}{1/200} \right] \quad (\text{検定比}) \quad (4)$$

$$\mathbf{t}_L = \begin{cases} 1 & \text{if } t_{R,j} \geq 1.0 \\ 0 & \text{otherwise} \end{cases} \quad (\text{制約条件の検定}) \quad (5)$$

学習データの生成は、10%以上が許容解、非許容解となるように設定し、かつ重複するデータがないように作成する。

4.2 NNの学習結果と考察

表6に示すパラメータで2つのNNモデルの学習を行う。損失関数は、model-Rは平均二乗誤差、model-Lは交差エントロピー誤差を用いて、式(6),(7)により定義する。

$$E_R(w) = \frac{1}{N} \sum_{j=1}^N (y_j - t_{R,j})^2 \quad (6)$$

$$E_L(w) = - \sum_{j=1}^N (t_{L,j} \log y_j + (1 - t_{L,j}) \log(1 - y_j)) \quad (7)$$

表 8 NN パラメータ

	model
ユニット	138-1500-1500-296
Epoch	2000
Batch size	1024
損失関数	交差エントロピー

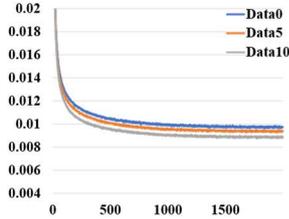


図 5 損失関数値の遷移

表 10 学習データ作成時の計算コスト [作成コスト] (%)

Data ₀	Data ₅	Data ₁₀
100	6748	10728

表 11 NN パラメータ

	Unit ₂₉₆	Unit ₃₂	Unit ₈
ユニット	138-1500-1500-296	138-1000-1000-32	138-500-500-8
Epoch	2000	2000	2000
Batch size	1024	1024	1024
損失関数	交差エントロピー	交差エントロピー	交差エントロピー

表 9 学習終了時の
正答率

Data ₀	96.8%
Data ₅	99.5%
Data ₁₀	99.6%

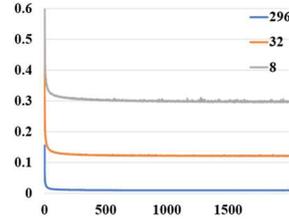


図 6 損失関数値の遷移

表 13 学習時の計算コスト [学習コスト] コスト (%)

Unit ₂₉₆	Unit ₃₂	Unit ₈
100	60.8	52.8

表 12 学習終了時の
正答率

Unit ₂₉₆	99.6%
Unit ₃₂	99.5%
Unit ₈	96.8%

ここで、N：出力値の数、y：出力値である。

学習結果としてそれぞれ 3 試行ずつ学習を行い、図 3、4 に学習時の 100 epoch ごとの検証データの正答率、表 7 に学習終了時の正答率を示す。正答率は、許容解を許容解、非許容解を非許容解と正確に判定したデータの割合として定義している。

表 7 より NN を分類器として用いた場合、検定比の予測をした場合と同程度以上の正答率を得られた。また、正答率の遷移では、model-R では振動がみられるが、model-L では安定した正答率を示している。これは、回帰モデルでは検定比の最小値が 0.0 で最大値は 10.0 を超えている場合があり、その影響があると考えられる。正答率の遷移に振動が見られる場合は、学習の終了判定次第で正答率が低いモデルになる可能性もあるため、制約条件の検定結果を NN による分類によって予測する手法は有効であることが判る。

5. 学習データセットの許容解比率による比較

5.1 モデルの作成

本節では、学習データセット内の許容解、非許容解の割合の違いによる学習結果の比較を行うため、以下の 3 つのデータを用意する。学習データセット生成において、Data₀ は設計変数をランダムに作成したデータとし、Data₅、Data₁₀ は各々、許容解が 5%、10%以上となるように作成したデータセットとする。

5.2 NN の学習結果と考察

表 8 に示すパラメータで 3 つの NN モデルの学習を行う。学習結果として、図 5 に学習時の 1 epoch ごとの損失関数値の遷移を、表 9 に学習終了時の検証データの正答率を示す。検証用データセットは、許容解:非許容解が 1:1 となるように作成したデータを用いる。表 10 に学習データセットの作成時の計算コストを Data₀ に対する割合で示す。

表 9 よりランダムの場合よりデータセット内の許容解の割合を指定したうえで、学習データセットを作成した場合

の方が推定精度の高いモデルを構築できることが判る。これは、ランダムに作成した学習データセットは許容解の比率が極端に小さくサンプルが少なくなるため、許容解を表すデータの学習がうまく行われず、殆どの変数で非許容解と判定される NN モデルが構築されたためである。

Data₅ と Data₁₀ の比較では、Data₅ の作成コストは Data₁₀ に対して 6 割程度であるが、正答率は同程度になっているため学習データセット内の許容解の割合は 5%で十分であると考えられる。

6. 出力層のサイズによる比較

6.1 モデルの作成

本節では、NN 学習の際に、検定に用いる部材や条件をグルーピングし、出力値 y を圧縮することで出力層のユニット数を変化させる。以下に示す 3 つのモデルを作成する。すべての部材でそれぞれの制約条件に対して個別に判定する出力層ユニット数 296 個のモデルを Unit₂₉₆ とし、Unit₃₂、Unit₈ は各々、各層でそれぞれの制約条件を判定する出力層ユニット数 32 個のモデル、各層ですべての制約条件を判定する出力層ユニット数 8 個のモデルである。

6.2 NN の学習結果と考察

表 11 に示すパラメータで 3 つの NN モデルの学習を行う。出力層のユニット数に対応させて中間層のユニット数を増減させる。学習データセットには、Data₅ を用いる。学習結果として、図 6 に学習時の 1 epoch ごとの損失関数値の遷移、表 12 に学習終了時の正答率を示す。また表 13 には各モデルの学習時の計算コストを Unit₂₉₆ に対する割合で示す。

図 6 より、損失関数値は Unit₂₉₆ が最も小さな値に収束していることが判る。学習終了時の正答率は Unit₂₉₆ と Unit₃₂ では同程度になっている。一般に NN は損失関数値が小さな値で収束するほど精度が高くなるが、出力層のユニット数がある一定以上であれば、ユニット数が検定の精度に影

表 14 GA パラメータ

	story					
	3	4	5	6	7	8
個体数	100	100	100	100	100	100
世代数	5000	10000	20000	50000	100000	200000
遺伝子長	8bit	8bit	8bit	8bit	8bit	8bit
突然変異率	0.01	0.01	0.01	0.01	0.01	0.01

表 15 規模別計算コスト(%)

story	GA-FEM	Data	Learning	GA-NN	Total
3	100	2500.0	110.0	6.0	2616.0
4	100	1250.0	55.0	6.5	1311.5
5	100	500.0	22.0	6.1	528.1
6	100	166.7	7.3	6.3	180.3
7	100	62.5	2.8	4.1	69.3
8	100	25.0	1.1	3.8	29.9

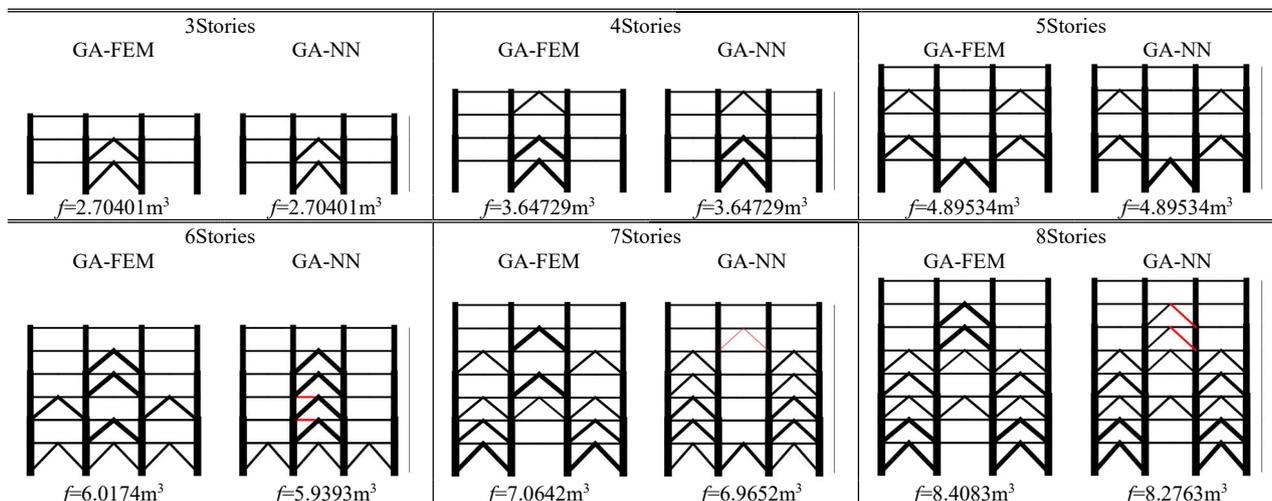


図 7 解形状

響を与えないことが判る。学習コストについては、ユニット数に応じて変化しており、Unit₂₉₆ が最も大きな値になっている。

7. GA を用いた最適化

7.1 FEM による最適化とサロゲートモデルによる最適化

解析モデルの 3-8 層を規模ごとに最適化を行う。ここで制約条件の検定に有限要素解析を用いる場合(GA-FEM)と NN の予測を用いる場合(GA-NN)をそれぞれ 3 試行行う。NN には Data₅ で学習した Unit₃₂ のモデルを用いる。また各規模での GA パラメータは表 14 に示すものを用いる。

7.2 数値結果と考察

最適化の結果として図 7 に得られた解形状を部材断面積と線の太さを対応させて示す。また、GA-NN により得られた解形状については、有限要素解析により制約条件を満たさない部材を赤色で表している。

GA-NN で得られた解形状は 3-5 層の場合は GA-FEM と同一の結果が得られている。しかし 6-8 層では GA-NN の目的関数値は GA-FEM よりも小さな値になっており制約条件を満たしていない部材が存在する解が得られている。NN で本来非許容解であるものが許容解であると危険側の誤った予測がされることがある。この結果より、高い正答率であるにもかかわらず最適解の近傍では誤答しやすいことが判る。6-8 層の場合では、制約条件を満たすには、多くのブレースが必要となり解空間が複雑なものになっている影響であると考えられる。

表 15 は各計算コストを規模ごとに GA-FEM に対する割合で表したものである。Data, Learning, Total は各々データ

セット作成、NN の学習、Data・Learning・GA-NN を合計した計算コストを意味している。GA-FEM と比較して、GA-NN の計算コストは小さく、高速で解を得ることができた。低層の解析モデルについてはデータセットの作成コストが非常に大きな割合となっている。規模によっては Total の計算コストが GA-FEM よりも大きな値になるが、一度の学習で異なる規模の最適化が可能であることは、計算コストの観点において優位であると考えられる。

8. まとめ

本稿では、サロゲートモデルを用いてブレース部材配置・断面の同時最適化を行った。NN の同時学習では高い正答率を得ることができたが、GA-NN で得られた解は非許容解であり、危険側の誤った近似解になることが判った。今後は、安全率として検定比を割り増ししたデータセットによる学習を行うなど、GA-NN による最適化での危険側の予測をなくす手法の模索を行っていく必要がある。

【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) 田村拓也,大崎純,高木次郎,: 機械学習を用いた鋼構造骨組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
- 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 次元橋梁モデルの曲げひずみエネルギー最小化-情報シンボ 2021,pp.323-326,2021
- 4) 本間俊雄,野端憲太: 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, pp35-43, 2007