機械学習による応答予測を用いた 鋼構造ブレース補強骨組の付加応力最小化

○木村 俊明^{*1} 大崎 純^{*2}
 田村 拓也^{*3} 高木 次郎^{*4}

キーワード:機械学習 SVM 焼きなまし法 組合せ最適化 鋼構造骨組 ブレース配置

1.序

骨組構造物の最適設計問題については、これまでに多く の論文が発表されており、小規模骨組構造物では数理計画 法や発見的手法を用いて容易に解くことができる¹⁾。焼き なまし法をはじめとした組合せ最適化に用いられる局所 探索法のプロセスにおいて、最適化の各ステップで実行さ れる構造解析の計算コストは、対象とする構造物が大規模 で複雑になるほど増加する。そのため、計算コストの削減 のためには、繰り返し行う構造解析の実行回数を削減する ことが有効である。

機械学習は,画像処理や自動操縦などに広く利用されて おり²⁾,建築分野では,建築設備のエネルギー負荷予測³⁾, 強震動予測⁴⁾,損傷度判定^{5,6)}などに取り入れられている。 しかしながら,構造最適化に機械学習を適用している研究 は現在ほとんど存在しない。

著者らは、機械学習を焼きなまし法に組み込み、各ステ ップの近傍解のうち、最適解の可能性が低い解の解析を省 略する手法を提案した^{7,8)}。しかし、これらの研究によっ て得られた学習結果は、異なるモデルの最適化には使用で きない。そこで、本研究では、小規模骨組構造物の機械学 習結果を利用し、より大きな規模の骨組構造物の最適化に 適用可能な予測手法を提案する。さらに、平面骨組の最適 化例を通して手法の有効性を検証する。

2. 機械学習

2.1 設計変数

図1に示すような、「ブレースなし」を含む5種類のブレースを、骨組の各構面に配置する設計問題を考える。骨組のスパン数と層数をそれぞれ n_s 、 n_f とすると、骨組架構の構面数は、 $m = n_s n_f$ となる。



各構面に設けるブレースの種類を図1のように1から5 までのインデックスを用いて表現する。第*i*構面の設計変 数を,5個のダミー変数 $y_i = (y_{i1}, y_{i2}, y_{i3}, y_{i4}, y_{i5})$ を用いて表 す。ここで、 $y_{ij} \in \{0,1\}$ (*j*=1,...,5)であり、それらのいず れかは 1,他の 4 個は 0 である。

ところで、骨組の応力は、隣接する構面のブレース配置 に大きく依存する。そのため、図2のグレーで示す4種類 の隣接パターンを考えてフィルター変数ベクトルxを作 成する。

変数 x の各成分の値は、図 3 に示すような畳み込み演算 によって評価する。それぞれのフィルターと一致する箇所 には1を、一致しない箇所には0を与える。

図 1 の 5 個の種類を考えると,図 2 の各パターンに 5×5=25 個のフィルター変数が存在する。したがって,例 えば 5 層 3 スパンの骨組では、フィルター変数の合計は 25×4×3×5=1500 個である。



図2.フィルターを定義するための4種類の接続関係



図 3. 畳み込み演算のイメージ

2.2 サポートベクターマシン(SVM)による学習

本研究ではサポートベクターマシン(以下 SVM)を用 いてブレース構造の性能を学習する。SVM では,次式で 定義される線形判別関数*S*(**x**)によって,分類を行う。

$$S(\mathbf{x}) = \mathbf{\beta}\mathbf{x} + b \tag{1}$$

ここで β , *b* は分離超平面を規定する重み係数ベクトル(以下,予測係数ベクトル)と係数である。

多数の設計解をランダムに生成して,優良解と非優良解 に分類し,それらの評価値(出力値)をそれぞれ1,-1と する。このように作成された入力データに対して,学習し, 交差検証で最も精度の高い結果を式(1)の予測係数ベクト ルとする。

2.3 大規模モデルへの適用

図1の5種類のブレースに対して図2の隣接関係で定め られる5×5×4=100種類のフィルターについて、フィルタ ーkに関するインデックス $\delta_k \in \{0,1\}$ を用いると、i層、jス パン構面の予測係数ベクトルの成分 β_i と係数bは、以下の ように表すことができる。

$$\beta_{ij} = \delta_1 \cdot \beta_{ij1} + \dots + \delta_k \cdot \beta_{ijk} + \dots + \delta_{100} \cdot \beta_{ij100}
b = \delta_1 \cdot b_1 + \dots + \delta_k \cdot b_k + \dots + \delta_{100} \cdot b_{100}$$
(2)

ここで,前節で示した学習結果を異なる層やスパンを持 つ架構に適用することを考える。式(2)は,機械学習の対象 となる骨組の規模の変化を十分に反映していないため,前 節で示した学習結果は,同一の骨組の評価に用いることは できるが,より大規模の骨組に対して適用はできない。そ のため,小規模骨組の機械学習によって得た予測係数にス ケーリングを施し,大規模の骨組に適用することができる 手法を提案する。以下では簡略化のため,階数のみ異なる 骨組を対象とする。

学習対象とする架構を骨組 1, 学習結果を適用する架構 を骨組 2 とし、それらの層数を n_{f1} 、 n_{f2} とする。また、予 測係数ベクトルをそれぞれ $\beta^{(1)}$ 、 $\beta^{(2)}$ 、骨組 1 の i B j スパ ンでのフィルターk の予測係数ベクトルの成分を $\beta^{(1)}_{ijk}$ とす る。骨組 2 の l B j スパンでのフィルターk の予測係数ベク トルの成分を $\beta^{(2)}_{ijk}$ と表し、層ごとに設定されたスケーリン グパラメータ c_{ij} を用いて

$$\beta_{ljk}^{(2)} = \sum_{i=1}^{n/1} c_{li} \beta_{ljk}^{(1)}$$
(3)

のように表す。さらに、予測係数ベクトル $\beta^{(2)}$ の $l \equiv j$ 番目スパンの成分 $\beta^{(2)}_{ii}$ は次のように計算できる。

$$\beta_{ij}^{(2)} = \delta_1 \cdot \sum_{i=1}^{n_{f1}} c_{ii} \beta_{ij1}^{(1)} + \dots + \delta_k \cdot \sum_{i=1}^{n_{f1}} c_{li} \beta_{ijk}^{(1)} + \dots + \delta_{100} \cdot \sum_{i=1}^{n_{f1}} c_{li} \beta_{ij100}^{(1)}$$
(4)

 $b_k^{(1)}$ は、予測係数 $\beta_{iik}^{(1)}$ を用いて

$$b_{k}^{(1)} = \sum_{i=1}^{n_{f1}} \sum_{j=1}^{n_{s}} \beta_{ijk}^{(1)}$$
(5)

のように定められる。設計変数 x において, l 層目に k 番目のフィルターが存在する場合に 1 の値を返す関数を T(x,k,l), 層ごとに設定されたスケーリングパラメータを r_l とし, $b_k^{(2)}$ を次式で求める。

$$b^{(2)} = \sum_{k=1}^{100} \sum_{l=1}^{n_{f2}} b_k^{(1)} r_l T(\mathbf{x}, k, l)$$
(6)

以上の係数を用いて, 骨組 2 における線形判別関数 S*(x)を次式で表す。

$$S^*(\mathbf{x}) = \boldsymbol{\beta}^{(2)} \cdot \mathbf{x} + b^{(2)} \tag{7}$$

2.4 最適設計問題と最適化アルゴリズム

耐震補強を想定し、地震荷重を想定した静的水平荷重の下で、ブレース設置による骨組部材の付加縁応力の最大値 $\sigma_{\max}(\mathbf{x})$ を最小化する。また、剛性を確保するため、最大

層間変形角 $\theta_{max}(\mathbf{x})$ に上限値を与える。さらに、各層に設置 可能なブレース数 n_b の上限値を 2 として最適設計問題を 以下のように定める。

Minimize	$F(\mathbf{x}) = \sigma_{\max}(\mathbf{x})$	
	$\theta_{\max}(\mathbf{x}) \leq 0.005$	(2)
subject to	$n_{\rm b} \leq 2$	

機械学習を組み込んだ焼きなまし法(SA)のアルゴリズ ムは以下のように書くことができる。

- Step 1. 許容解を10000個ランダムに発生し,上位10% を優良解,下位10%を非優良解として機械学 習を行う。
- Step 2. 初期の許容解をランダムに生成し,温度パラメ ータTを1.0とする。また,初期解で目的関数 が 10%増加した時の受理確率が 0.5 になるよ うに,スケーリングパラメータsを定める。
- Step 3. 現在の解候補 x から変数を 3 つランダムに変 化させた近傍解を 15 個生成し,優良解,非優 良解の分類を行う。
- Step 4. 優良解に分類された近傍解に対して構造解析 を行い, F(x)を求める。近傍解の中で最も評 価が改善する解 x' が F(x')≤F(x)を満たせば その解を受理する。F(x')>F(x)であれば, T と s で定められる確率で近傍解を受理する。
- Step 5. $T \leftarrow \alpha T$ ($\alpha = 0.92$)により温度を更新する。
- Step 6. 温度更新回数が 100 に達していれば最良解を 出力して終了し,達していなければ Step 3 に 戻る。

通常のSAの場合,各ステップで全ての近傍解の構造解 析を行う必要があるが,機械学習を利用すれば,式(7)の S*(x)に基づき,閾値以上のスコアを持つ解のみに対して のみ構造解析を実行すればよい,これにより計算時間の削 減が可能となる。

3. 数值解析例

3.1 解析モデル概要

機械学習の対象骨組は図4に示す5層3スパン鋼構造骨 組とする。設計荷重を表1に,部材断面を表2,3示す。学 習結果を適用する大規模骨組は,図5に示す10層3スパ ンの骨組とする。設計荷重を表4に,部材断面を表5,6に 示す。2つのモデルともに,基礎梁には十分に大きい断面 2次モーメントを与える。

解析コードには汎用骨組解析プログラム OpenSees⁹⁹を 使用する。構造解析は弾性解析とし、ブレースの座屈と塑 性化については考慮しない。柱梁は Beam-Column 要素で モデル化する。剛床仮定を近似的に表現するため、梁の軸 剛性を 10 倍する。支持条件は柱脚で固定支持とする。

5層骨組の機械学習の結果を10層骨組に適用したケー



表 1. 設計荷重				
Floor	Qi (kN)			
R	465			
5	702			
4	887			
3	1026			
2	1123			

Floor	部材断面	A (cm ²)	Iz (cm4)	
R	$\text{H-}346{\times}174{\times}6{\times}9$	52.45	11000	
5	$\text{H-}350\!\times\!175\!\times\!7\!\times\!11$	62.91	13500	
3, 4	$\text{H-}396\!\times\!199\!\times\!7\!\times\!11$	71.41	19800	
2	$\text{H-400}{\times}200{\times}8{\times}13$	83.37	23500	

表2.5 層骨組の部材断面(梁. SN400B)

表 3.5 層骨組の部材断面(柱・筋交い, SN400B)

	部材断面	A (cm ²)	Iz (cm ⁴)
柱	\Box -350×350×9	122.8	23800
筋交い	$\text{H-}250\!\times\!125\!\times\!6\!\times\!9$	36.97	3960



表	4.	設計偷車

Floor	Qi (kN)
R	584
10	875
9	1119
8	1327
7	1506
6	1658
5	1784
4	1885
3	1963
2	2017

表 5. 10 層骨組の部材断面(梁, SN4	00B))
-------------------------	------	---

Floor	动材料	А	\mathbf{Iz}
Floor	田 1억 (까이리	(cm^2)	(cm ⁴)
R	H-346×174×6×9	52.45	11000
10	H-350×175×7×11	62.91	13500
8, 9	H-396×199×7×11	71.41	19800
6, 7	H-400×200×8×13	83.37	23500
4, 5	H-386×299×9×14	117.4	32900
2, 3	H-390×300×10×16	133.3	37900

表 6.10 層骨組の部材断面(柱・筋交い, SN400B)

	部材断面	A (cm ²)	Iz (cm ⁴)
柱	\Box -400×400×12	182.5	45300
筋交い	$\text{H-}250\!\times\!125\!\times\!6\!\times\!9$	36.97	3960

スを Case-1, 10 層骨組に対して構造解析を行って機械学 習を実行した解析ケースを Case-2 とする。また,本手法 の有効性を確認するため,機械学習を用いず,通常の SA のみで最適化を行ったケースを Case-3 とする。

3.2 応答予測結果

式(3)の係数*c_{ii}* は表 7 のように定める。10 層骨組の最 上層と最下層は、5 層骨組の最上層と最下層に対応させ、 その他の層には 5 層骨組の複数層に重みを与える。ま た,式(6)の*r_i*の値は、1~3 層は 0.05、4~6 層は 0.10、7 ~10 層は 0.03 とする。

優良解を非優良解と判断した数を FN, 非優良解を優 良解と判断した数を FP とする。最適化過程で優良解と 非優良解を選択するための閾値は, FN を抑えることを 重視し, 関数 $V_{c} = N_{FN} + 0.8N_{FP}$ が最小となるように,表 8 に示す値を定める。ここで, N_{FN} , N_{FP} は, それぞれ FN と FP の数である。表 8 の計算は 10000 個の解に対して 解析を行った結果を用いている。ただし, 1000 個の解 に対しても同様の結果が得られることを確認している。

以上のパラメータ値を用いて Case 1,2 に対して予測 を行った結果を表 9 に示す。数が多いほど設計解を誤 って判断していることを示している。予測結果と比較 すると,FN と FP それぞれの増加量は,優良解及び非 優良解の数(1000 個)の5%以内に収まっており,高い 精度で予測できていることが分かる。

表 7. 式(3)の係数 c₁₁

層 ())	c_{l1}	c_{l2}	<i>C</i> ₁₃	c_{l4}	<i>C</i> ₁₅
最下層	1	1.0				
	2		1.0			
下屋	3		0.5	0.5		
	4		0.5	0.5		
	5			1.0		
	6				1.0	
上層	7				0.5	0.5
	8				0.5	0.5
	9					1.0
最上層	10					1.0

3.3 最適化結果

ランダムに生成された初期値を用いて最適化を行う。

表 8. 優良解と非優良解の閾値

閾値	FN	FP	V _c
-50	0	992	793.6
-40	0	960	768.0
-30	5	872	702.6
-20	38	701	598.8
-10	125	421	461.8
0	377	170	513.0
10	719	41	751.8

表 9.10 層骨組の分類精度

	FN	FP
Case-1	178	181
Case-2	135	133
FN, FP の増加量	43	48

Case-1,3 の手法にて、20 回最適化を行い,最も目的関数が小さい値を示したときの結果を表10 および図6に示す。表に示す解析回数は,機械学習時の解析も含んでいる。得られた結果より,解析回数は35%程度削減できていることがわかる。また,最適解の目的関数およびブレース配置は同一となる。このことから,本手法を用いることにより計算時間の削減を実現し,且つ効率よく最適化が行われていることがわかる。

表 10. 最適化の結果比較

	Case-1	Case-3
解析回数 (回)	147737	223840
目的関数	78 70	79 70
(N/mm ²)	/8./9	/8./9



図 6.10 層骨組の最適解

4.結論

小規模骨組構造物の機械学習結果に基づき,より大 規模な骨組構造物の最適化に適用可能な予測手法を提 案し,数値解析例を通して有効性を確認した。

本稿で得られた知見は以下のようにまとめられる。

 小規模骨組の学習結果を用いることで、大規模骨 組の優良解・非優良解の予測を行うことが可能で ある。

 異なる規模の骨組の学習結果を用いることにより、 最適解の精度を落とすことなく、SAによる最適化 を効率化することが可能である。

謝辞

本研究の一部は、日本学術振興会・科研費(16H04449, 16H03014,18K18898)の助成を得た。ここに記して謝意 を表する。

[参考文献]

- Saka MP, Geem ZW, Mathematical and metaheuristic applications in design optimization of steel frame structures: An extensive review, Mathematical Problems in Engineering, Article ID 201031, 2013.
- 原田達也,機械学習の画像認識への応用,シミュレ ーション, Vol. 34, pp. 240-246, 2015
- 3) 塩谷正樹,矢入建久,桝川依士夫,吉田圭吾,機械学 習アプローチによる建築設備のエネルギーフォルト 検知に関する研究 -(その 1)次元削減と共起ルール のパターン化による非特定型エネルギーフォルト解 析・,空気調和・衛生工学会大会学術講演論文集, Vol.2009.1, pp.529-532, 2009
- 4) 宮本 崇 本田利器, 不確実性を反映した多数の想定 地震動の特性の機械学習に基づく設計地震動の合成, 理論応用力学講演会講演論文集, Vol. 63, p. 23, 2014
- 5) 広兼道幸,野村泰稔,楠瀬芳之,コンクリート構造 物のひび割れ形状に基づく損傷度分類への線形 SVM の適用,土木学会論文集 A, Vol. 64, pp. 739-749, 2008
- 6) 由良慎弥,中村秀治,藤井 堅,階層型ニューラルネ ットワークを用いた構造物の損傷部材推定システム の実験的検討,土木学会第 66 回年次学術講演会, pp.1095-1096,2011
- 7) 田村拓也,大崎純,高木次郎,鋼構造骨組のブレース配置の組合せ最適化,第12回最適化シンポジウム 講演論文集,日本機械学会,No. 2208, 2016.
- T. Tamura, M. Ohsaki and J. Takagi, Machine learning for combinatorial optimization of brace placement of steel frames, Japan Architectural Review, 2018.
- 9) Open System for Earthquake Engineering Simulation (OpenSees), PEERC, UC Berkeley.: http://opensees.berkeley.edu/
- *1 京都大学 助教・博士 (工学)
- *2 京都大学 教授・博士(工学)
- *3 清水建設株式会社 (元京都大学大学院生)
- *4 首都大学東京 准教授·Ph.D