

機械学習による小規模ブレース付骨組の特徴分析と それに基づく大規模骨組の最適化

Optimization for Large-scale Frames Based on Machine Learning for Feature Analysis of Placement of Braces of Small-scale Frames

○阪口 一真^{*1}, 大崎 純^{*2}, 木村 俊明^{*3}
Kazuma Sakaguchi^{*2}, Makoto Ohsaki^{*2} and Toshiaki Kimura^{*3}

*1 京都大学大学院工学研究科大学院生

Graduate Student, Graduate School of Eng., Kyoto Univ.

*2 京都大学大学院工学研究科 教授・博士 (工学)

Professor, Graduate School of Eng., Kyoto Univ., Dr. Eng.

*3 京都大学大学院工学研究科 助教・博士 (工学)

Assist. Prof., Graduate School of Eng., Kyoto Univ., Dr. Eng.

キーワード：機械学習；サポートベクターマシン；特徴量分析；非線形カーネル；ブレース配置最適化；鋼構造骨組

Keywords: Machine learning; support vector machine; feature analysis; nonlinear kernel; optimization of brace placement; steel frame.

1. はじめに

建築構造物のトポロジー最適化に用いられる焼きなまし法(SA)などの発見的な手法において、計算量を低減するためには探索点での構造解析の実行回数を削減するのが有効である。田村ら[1, 2]は、平面骨組のブレース配置の組合せ最適化問題において、焼きなまし法に機械学習を導入することで、応答量が優良でない近傍解の構造解析を省略する手法を提案した。

また、一般に機械学習において、次元の呪いにより、学習データの次元が増えるにしたがって学習に要する計算量は爆発的に増加する一方、その汎化能力は低下する。そのため、小規模で低次元の学習データを用いて作成した分類器を高次元のデータに適用させることは、学習を現実的なものとする上で重要である。著者ら[3]は、既報[2]で提案された方法を拡張し、部材応力の絶対値の最大値や外力仕事を評価指標として様々な大規模骨組に対して小規模骨組での分類器の適用する手法を提案した。

本稿では既報で示された数値例題より大規模な骨組に対しても、小規模骨組での分類器をもとに最適化時の解析回数の低減が可能であることを検証する。

2. 最適化問題の定式化

図 1 に示す n_f 層 n_s スパンの鋼構造平面骨組のモデルを対象とし、骨組の応答量を目的関数として各構面に配置するブレースの組合せを最適化する。

地震時の付加応力のみを考えるため、 A_i 分布に基づく静的地震力のみを考慮する。また、せん断力の梁・柱と

ブレースによる伝達を考慮するため、剛床仮定とせず梁部材の軸剛性を 10 倍に設定して解析を行う。柱脚は固定支持とする。

設計変数の数 m は、骨組の構面数と一致し、 $m = n_f n_s$ となる。図 1 のように、 m 個の構面に配置されるブレースの種類としてブレースなしを含めた計 5 通りを想定し、対応する値を定める。設計変数ベクトル \mathbf{x} は以下のように表される。

$$\mathbf{x} = (x_1, x_2, \dots, x_m) \quad \text{ただし, } x_i \in \{0, 1, 2, 3, 4\} \quad (1)$$




図 1. 骨組モデル (左) とブレースの種類 (右)

目的関数となる骨組の応答量は、各部材の最大縁応力 $\sigma_i(\mathbf{x})$ の絶対値について、 p -ノルムを考える (以下の例では $p=10$)。制約条件として、第 i 層に設置できるブレース数 n_{bi} に指定値 \bar{n}_b を与え、柔な解を除去するため層間変形角の最大値 $r_{\max}(\mathbf{x})$ に上限値 \bar{r} を与える。ブレース

を含めた部材数を M として、最適化問題を以下のように定式化する。

$$\begin{aligned} \text{Minimize} \quad & F(\mathbf{x}) = \left(\sum_{i=1}^M |\sigma_i(\mathbf{x})|^p \right)^{\frac{1}{p}} \\ \text{Subject to} \quad & n_{bi} = \bar{n}_b \quad (i=1, 2, \dots, n_f) \\ & r_{\max}(\mathbf{x}) \leq \bar{r} \end{aligned} \quad (2)$$

3. 機械学習の概要

3.1. サポートベクターマシン (SVM)

機械学習の手法の1つである SVM は、事例 \mathbf{x} の集合を線形あるいは非線形関数によって2つのクラスに分類するのに最適な係数 α_i^*, b^* を見つけるアルゴリズムである。学習データ (事例とラベル y のペア) の n 個のセット $((\mathbf{x}_1, y_1), \dots, (\mathbf{x}_i, y_i), \dots, (\mathbf{x}_n, y_n))$ に対し、分類の基準となるスコア $S(\mathbf{x})$ は RBF (radial basis function, 放射基底関数) をカーネル関数とすると以下ようになる。ここで、 k は倍率を定めるパラメータである。

$$S(\mathbf{x}) = \sum_{i=1}^n \left\{ y_i \alpha_i^* \exp \left(-\frac{\|\mathbf{x}_i - \mathbf{x}\|_2^2}{k^2} \right) \right\} + b^* \quad (3)$$

SVM は通常は順序尺度の変数に対して用いられるため、入力 \mathbf{x} が名義尺度の場合、2値化を行う[4]。図1の5種類のブレースに対して、図2のように2値化する。




図 2. 5 種類のブレースの 2 値化

3.2. 小規模骨組の学習と評価の方法

ランダムに 10000 個の許容解を生成し、学習データを作成する。クラス分類は、目的関数の小さい解から上位 10% 優良解 ($y=+1$)、下位 10% を非優良解 ($y=-1$) とする。

表 1. 予測値と学習データの組合せ対応表

		学習データのラベル	
		+1	-1
SVM の予測したラベル	+1	真陽性 TP	偽陽性 FP (false positive, 誤検知)
	-1	偽陰性 FN (false negative, 見逃し)	真陰性 TN

学習データと同様にして、優良解・非優良解の評価用データを作成する。表1に示すような FN (false negative,

見逃し) や FP (false positive, 誤検知) となったデータの個数と、誤差率 (FN または FP となったデータ数の学習データ総数に対する割合) を算出する。ここで、FN は SVM が優良解を非優良解と判断した数、FP は非優良解を優良解と判断した数である。

線形カーネルの場合、特徴量のラベルの値への寄与度は重みベクトルの各成分の値により求めることができる。一方、非線形の RBF カーネルでは、重みベクトルをそのまま用いて評価することができない。本研究では、重みベクトル β' を定義して特徴量の寄与度を評価する[5]。

β' の j 番目の要素 β'_j は次式のように定める。ただし、 t_j, o_j は j 番目の特徴量において 1 及び 0 を標準化したもので、 s_j は、 j 番目の特徴量における \mathbf{x} の標準偏差であり、 x_{ij} は \mathbf{x}_i の j 番目の成分である。

$$\beta'_j = s_j \sum_{i=1}^n y_i \alpha_i^* \left[\exp \left\{ -\frac{(x_{ij} - t_j)^2}{k^2} \right\} - \exp \left\{ -\frac{(x_{ij} - o_j)^2}{k^2} \right\} \right] \quad (4)$$

3.3. 大規模骨組への適用

n_{f1} 層の小規模骨組の学習結果に基づく式(3)の値は、 $n_{f2} (> n_{f1})$ 層の大規模骨組にそのまま適用できない。そこで、重み係数の行列 \mathbf{C} および優良解・非優良解の閾値を定めるバイアス b^* を用いて以下の手順に従い、式(3)に代入する事例 \mathbf{x} の次元数を削減する。

Step 1. ベクトル \mathbf{x} を n_{f2} 行 5 列の行列 $\mathbf{X}^{n_{f2}}$ に置き換える。このとき各行の成分は小規模骨組の各層、5つの列は2値化したブレースの種類を表す数値とする。

Step 2. n_{f1} 行 n_{f2} 列の重み係数の行列 \mathbf{C} を用いて、次式より行列 $\mathbf{X}^{n_{f1}}$ を求める。

$$\mathbf{X}^{n_{f1}} = \mathbf{C} \mathbf{X}^{n_{f2}} \quad (5)$$

Step 3. 行列 $\mathbf{X}^{n_{f1}}$ から小規模骨組の次元に縮約した設計変数ベクトルを計算する。

\mathbf{C} の各行の成分は縮約後のモデルにおける各層の重み係数に対応し、各列は縮約前のモデルに対応する。 \mathbf{C} と b^* は次の最適化問題を解いて求める[3]。

Find \mathbf{C}, b^*

$$\text{Minimize} \quad V_c = \frac{\sum_{\mathbf{x}_i \in (\text{fn} \cup \text{fp})} S(\mathbf{x}_i)^2}{s_s^2} + w_1 \sum_{i,j} |c_{ij}| + w_2 R \quad (6)$$

Subject to $c_{ij} \geq 0 \quad (i=1, 2, \dots, n_{f1}, j=1, 2, \dots, n_{f2})$

ここで、 s_s^2 はスコア $S(\mathbf{x}_i)$ の全学習データでの分散、fn, fp はそれぞれ FN, FP となったデータの集合、 w_1, w_2 は任意に定めた重み係数 (以下の例では $w_1 = 0.05, w_2 = 2$)、 R はスコア-目的関数間の相関係数である。最適化には逐次2次計画 (SQP) 法を用いる。

表 2. 骨組の部材断面

12 層モデル						24 層モデル									
柱梁断面		A [cm ²]	Iz [cm ⁴]	ブレース断面		A [cm ²]	Iz [cm ⁴]	柱梁断面		A [cm ²]	Iz [cm ⁴]	ブレース断面		A [cm ²]	Iz [cm ⁴]
11G-RG	H-390x300x10x16	133.3	37,900	11F-12F	[-100x50x5x7.5]	11.92	188	19G-RG	H-450x200x9x14	95.43	32,900	19F-24F	2L-65x65x6	15.05	58.8
8G-10G	H-488x300x11x18	159.2	68,900	8F10F	[-125x65x6x8]	17.11	424	13G-18G	H-500x200x10x16	112.3	46,800	13F-18F	H-100x100x6x8	21.59	378
2G-7G	H-588x300x12x20	187.2	114,000	2F-7F	[-150x75x6.5x10]	23.71	861	2G-12G	H-600x200x11x17	131.7	75,600	2F-12F	H-125x125x6.5x9	30.00	839
1C-12C	□-400x400x16	237.0	57,100	1F	[-150x75x9x12.5]	30.59	1050	1C-24C	□-600x600x28	600.3	314,000	1F	H-150x150x7x10	39.65	1620

4. 最適化アルゴリズム

焼きなまし法と機械学習の手法を用いて、最適化を以下のように実行する。

- Step 1. 優良解・非優良解 1000 個ずつの学習データから、SVM の分類器を作成する。また、式(6)の最適化問題を解き、 \mathbf{C} と \mathbf{b}^* を求める。
- Step 2. ランダムに初期の許容解を生成する。初期温度 $T=1.0$ を与える。初期解で、目的関数が 10% 増加したときの受理確率が 1/2 となるようにスケールリングパラメータ s_p を設定する。
- Step 3. 現在のステップにおける暫定解から、1 層毎に 1/10 の確率でランダムにブレース配置を変化させ、制約条件を満たす近傍解を 50 個生成する。
- Step 4. 近傍解の次元数を行列 \mathbf{C} により削減し小規模骨組の SVM 分類器を用いて評価を行う。スコアが閾値以下の近傍解は解析せずに棄却する。
- Step 5. 構造解析を行い、目的関数を計算する。
- Step 6. 近傍解のうち最も目的関数が小さい解について、暫定解より目的関数が改善されている場合、その近傍解を受理する。改善されていない場合でも T と s_p より定められる確率でその解を受理する。
- Step 7. 現在のステップでの解析回数で生成した近傍解の半数 (25 回) 未達なら閾値を下げ、半数以上なら閾値を上げることで、近傍解の半数程度を解析するようにスコアの閾値を更新する。
- Step 8. 温度更新パラメータを $c_p (=0.92)$ として、温度パラメータを $T \leftarrow c_p T$ とする。
- Step 9. 温度更新回数が 3000 回に達していなければ、Step 3. に戻る。達していれば、最も目的関数が小さい解を出力して終了する。

5. 数値例題

焼きなまし法による最適化と静的骨組解析のプログラムは MATLAB を用いて作成し、機械学習には Statics and Machine Learning Toolbox を、SQP 法での最適化には Optimization Toolbox を使用する。12 層 4 スパンの骨組で作成した SVM 分類器を 24 層 4 スパンの骨組に適用する。階高は 3 m、スパン長は 6 m とする。部材断面を表 2 に示す。設計用床荷重は最上階のみ 10 kN/m² とし、残り

の階は 8 kN/m² とする。鋼材のヤング率は 2.05×10^5 N/mm² とする。 $\bar{r} = 1/200$, $\bar{n}_b = 2$ とする。

5.1. 小規模骨組の学習結果

SVM による学習結果を表 3 に示す。線形カーネルより非線形の RBF カーネルの方が誤差は小さく、非線形のカーネル関数による学習精度の向上が見られる。

表 3. 小規模骨組 (12 層 4 スパン) の学習結果

線形カーネル			RBF カーネル		
誤差	FN	FP	誤差	FN	FP
10.35 %	105/1,000	102/1,000	8.00 %	85/1,000	75/1,000

次に、優良解に寄与する特徴量の上位 6 つを図 3 に示す。ここで、優良解のほとんどで、応力の絶対値の最大値 (以下、最大応力) はブレースの材端で発生している。どちらのカーネル関数も、1, 2 層及び 7 層の特徴量が選ばれており、これらの層のブレース配置が骨組の応答量を低減するために重要であると考えられる。とくに 7 層では梁とブレースの部材寸法が下層と異なるため、層剛性が変化している。これによりブレースの最大応力が大きくなったことが影響していると考えられる。




図 3. 優良解への寄与度の大きい特徴量


5.2. 大規模骨組の学習精度の確認

12 層骨組の学習結果を 24 層骨組への適用した結果と、24 層骨組のモデル自体を用いて作成した SVM 分類器による評価結果を表 4 に示す。小規模骨組の分類器を用いると、実際に大規模骨組に対して学習を実行した場合と

比べて誤差率は 20% ほど増加したが、それぞれの誤差率の値は数% 程度と小さく、いずれの場合も高い精度で予測できていることが分かる。

表 4. 分類の精度の比較

12 層の学習結果を使用			24 層で学習		
誤差	FN	FP	誤差	FN	FP
2.70 %	32/1,000	22/1,000	2.30 %	8/1,000	38/1,000



また、行列 C は式(7)のようになる。濃いグレーは大きい値を示しており、最下層や最上層に対応する行に多くの非ゼロ成分が分布していることがわかる。このことから、最下層や最上層のブレース配置が優良解・非優良解の分類に重要であると考えられる。

5.3. 最適化例

4 節で示した機械学習を用いた SA の手法と、4 節の手法のうち Step 1, 4, 7 を含まない通常の SA による結果を比較して、提案手法の有効性を検証する。各手法で 10 回ずつ最適化を行い、それぞれ最良の結果を表 5 に示す。ここで、学習データを作成する時間、および、行列 C とバイアス b^* の最適化する時間は、解析時間には含まないものとする。最適解の模式図は応力図であり、色の濃い

ものが応力の絶対値が最大の部材を示す。

表 5 に示すとおり、機械学習を用いた SA では、ステップごとにスコア関数の閾値を調整することで、解析がほぼ半数となっているものの、通常の SA と比べて目的関数の値に大きな

差は見られない。本数値例題の場合、目的関数を SVM で評価するのに必要な時間は、その解の解析に必要な時間のおよそ 1/14 であり、最適化の試行回数を多くするなどして解析回数が増えるほど、提案手法が有効になる。

6. 結論

本稿では、小規模骨組の分類器の特徴を分析し、層数の異なる大規模骨組へ適用可能であることを示した。また、大規模骨組に適用可能な SVM 分類器を用いて、既報よりも規模の大きな骨組ブレースの最適配置問題の計算量を低減した。

謝辞

本研究の一部は科研費 No. JP18K18898 による。ここに記して謝意を表する。

【参考文献】

- 1) T. Tamura, M. Ohsaki and J. Takagi, Machine learning for combinatorial optimization of brace placement of steel frames, Japan Architectural Review, Vol. 1(4), pp. 419-430, 2018.
- 2) 田村拓也, 大崎純, 木村俊明, 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性能予測と組合せ最適化, 日本建築学会大会学術講演梗概集(東北)構造 I, pp.375-376, 2018.
- 3) 阪口一真, 大崎純, 木村俊明: 機械学習を用いた大規模鋼構造骨組のブレース配置の性能予測, 2019 年度日本建築学会近畿支部研究発表会, 2019.
- 4) 石村貞夫, 石村光資郎: 入門はじめての多変量解析, 東京図書, 2007.
- 5) 阪口一真, 大崎純, 木村俊明: 機械学習を用いた鋼構造骨組の最適ブレース配置の特徴抽出, 日本建築学会大会学術講演梗概集(北陸)構造 I, pp.195-196, 2019.

表 5. 最適化の結果の比較

	予測ありの SA	通常の SA
総解析時間	4077 s	7611 s
分類器の作成時間	0.67 s	0 s
近傍解の評価時間	272.9 s	0 s
解析回数	75,262	150,000
目的関数	294.6 N/mm ²	295.0 N/mm ²
最適解		