

機械学習と疑似焼きなまし法を用いた 鋼構造骨組のブレース配置の組合せ最適化

○田村 拓也*¹ 大崎 純*²
高木 次郎*³

キーワード：機械学習 組合せ最適化 SA 二分木 サポートベクターマシン

1. 序

既存建築構造物の耐震補強時に用いる鉄骨ブレースの配置にはさまざまな組み合わせが考えられる。耐震補強の際には、耐震強度の向上のみならず、既存骨組部材への影響を最小限にとどめることも重要である[1]。

中規模以上の建築構造物ではブレース配置の組合せは膨大な量になり、最適化時に必要な計算量は非常に多くなるため、計算量を可能な限り削減できるような最適化アルゴリズムを考案する必要がある[2-4]。

本研究では、静的荷重の作用する鋼構造骨組を対象として、ブレースの種類および配置を最適化するアルゴリズムを作成し、機械学習の手法を導入することにより、少ない計算量で最適化することを目的とする。

2. 最適化の手法

2.1. 最適化アルゴリズム

本研究で対象とするブレース配置の最適化問題は、組合せ最適化問題に分類されるため、整数変数を容易に扱うことができ、制約を満たさない解が存在する場合にも有効な局所探索法に基づく発見的手法の一つである疑似焼きなまし法(SA)を用いる。

本研究で用いるSAによる最適化アルゴリズムを以下に示す。

Step 1. 4種類のブレースおよびブレースを持たない骨組構面を、それぞれ図1のように変数の値1, 2, 3, 4, 5で定める。フレームの m 番目の設置箇所に選択されるブレースの種類を設計変数 $\mathbf{x} = (x_1, x_2, x_3, \dots, x_m)$, ($x_i \in \{1, 2, 3, 4, 5\}$)とし、制約条件を満たす初期解をランダムに生成する。

Step 2. 温度パラメータ T に初期温度1.0を設定する。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、スケールパラメータ s を次式で定める。

$$s = -(0.1 * F(\mathbf{x}_0)) / \log(0.5)$$

Step 3. 現在の解候補 \mathbf{x} から変数を複数ランダムに変化させた近傍解を指定された数だけ生成する。近傍解に対して解析を行い、目的関数 $F(\mathbf{x})$ の値を求める。近傍解

の中で最も評価が改善される解 \mathbf{x}' が $F(\mathbf{x}') \leq F(\mathbf{x})$ を満たせばその解を受理する。 $F(\mathbf{x}') > F(\mathbf{x})$ であれば、以下の式から近傍解の受理確率 p を求め、一様乱数 $0 \leq r \leq 1$ が p 以下であれば近傍解を受理する。

$$p = \exp\left(-\frac{|F(\mathbf{x}') - F(\mathbf{x})|}{T \times s}\right)$$

Step 4. 温度更新パラメータを $\alpha < 1$ として、 $T \leftarrow \alpha T$ に温度を更新する。以下の例では $\alpha = 0.92$ とする。

Step 5. 温度更新回数が指定値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。




図1. ブレースの種類

2.2. 機械学習を用いた解の予測

前項で示したアルゴリズムでは、ステップごとに多くの骨組解析を実行する必要がある。よって、解析実行前に解の優劣を予測し、優良解とはならない解の解析を省略することができれば最適化に要する時間を削減できる。

変数の組合せとその特徴量の関係を定量化し、未知の情報を予測するための手法の一つに機械学習がある。以下ではMatlabに実装されている機械学習アルゴリズムのうち二分木、サポートベクターマシン(以下SVM)の2つを用いて解の学習を行う[5]。

2.2.1. 学習データの作成

機械学習のアルゴリズムには大量のサンプルデータが必要となるため、以下の手順でデータを10000個用意する。

Step 1. 2.1節で定めた設計変数に従いランダムに解を生成する。

Step 2. 骨組解析を行い、目的関数の値を求める。制約条件を満たさない場合はStep 1に戻る。

Step 3. 以上の操作から得られた設計変数と目的関数の組を1つの解とし、生成した解の数が10000個に達していなければStep 1に戻る。

2.2.2. 変数の前処理

i) 2 値化

SVM や二分木は、通常は順序尺度の変数に対して使用され、ブレースに番号を割り振るカテゴリカルな変数では順序に意味がないため、上記の変数をそのまま使用するのは望ましくない。そのため、変数をダミー変数に変換することで 2 値化する。

ダミー変数とは、カテゴリカルな変数を {0, 1} の 2 値の配列に変換した形式の変数である。上記の問題では、変数が {1, 2, 3, 4, 5} の値をとるため、各変数値が選択されるとき 1、選択されないとき 0 の 2 値変数で表現でき、変数値が 4 であれば 00010 といった形式に変換される。

ii) 畳み込み処理

ブレース配置の特性を学習するためには、各所に設置されたブレース単体を見るのではなく、図 2 に示すように隣接するブレースとの接続関係を検討するのが望ましい。それらのブレースの組合せの存在 / 非存在を特徴量として抽出するために、畳み込み演算を行う。




図 2. ブレースの組合せ

タテに隣接する斜めブレースの組を 1 つのフィルターとして使用して畳み込み演算を行った例を図 3 に示す。フィルターの内容と一致するパターンが存在する箇所の変数を 1、存在しない箇所には 0 を割り当てることで、1 つのフィルターにつき次元数 15 の特徴量を得る。




図 3. 畳み込み演算

iii) プーリング

畳み込み演算によって解の特徴量を抽出することができるが、全フィルターに対して実行するため図 3 の例では次元数が 1500 と膨大になってしまう。次元数の大きさに比例して解の予測にかかる時間が増大してしまうため、次元数の削減を行う。

図 4(a), (b) のように、同じパターンの組合せが同一層に

配置されており、これらを区別する必要性が高くない場合には、(c) のように、両配置を同一のものとして見なすことができる。このように、位置感度を下げることによって特徴量の次元を削減する行為をプーリングとよぶ。




図 4. プーリング

iv) クラス分類

学習アルゴリズムを使用することにより、優れた配置 (以下優良解) の持つ傾向や特徴を学習し、劣った配置 (以下非優良解) であると予測される解について骨組解析を行わないようにしたい。

SVM および二分木は「教師あり学習」と呼ばれ、あらかじめ学習データに対しクラスラベルを人為的に指定しておく必要がある。そのため、優良解、非優良解の基準を定めてクラスラベルを割り振った上で学習を実行する。

2.3. 機械学習の最適化アルゴリズムへの適用

前節で紹介した機械学習の手法を用いることによって、2.1 項で示した最適化アルゴリズムを以下のように修正することができる。

- Step 1. ランダムに発生させた 10000 個の許容解に対し、Matlab の二分木もしくは SVM の関数を用いて学習を行う。
- 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 に初期温度 1.0 を設定する。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 \mathbf{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、解に対し優良解、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設計用荷重を与えて解析を行い、目的関数の値を求める。近傍解の中で最も評価が改善される解 \mathbf{x}' が $F(\mathbf{x}') \leq F(\mathbf{x})$ を満たせばその解を受理する。 $F(\mathbf{x}') > F(\mathbf{x})$ 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。

なお、Step 3 で行う優劣の判定に用いる閾値は、学習方

法や制約条件の厳しさによって適正値が変動するため、閾値 t の初期値を 0.0 とし、以下の手順で動的に変動させる。

- Step 1. SA の Step 3 開始時に $t = t + 0.03$ を代入する。
- Step 2. 各近傍解に対して predict 関数を用いた予測を行い、出力されたスコアが t 以下であれば優良解と見なし解析を実行する。
- Step 3. 解析実行後に出力された目的関数が前 Step 終了時の最良解よりも指定値以上大きい場合は $t = t - 0.01$ を代入し、閾値の制約を厳しくする。

3. 機械学習と最適化の結果

3.1. 解析モデル

図 5 に示す均等なスパン幅を持つ 5 層 3 スパンの鋼構造骨組を対象とする。設計用荷重算出用の奥行きは 6m とし、部材の断面性能および設計用地震力を表 1 に示す。耐震改修を想定し、ブレースの設置にともなう梁・柱の応力の増加量を制約する。したがって、解析時には設計用長期荷重（鉛直荷重）は与えず、長期荷重からの増加量分（地震力）のみを与える。

解析コードには汎用骨組解析プログラムである OpenSees[6] を使用し、柱梁およびブレースを弾性の Beam-Column 要素でモデル化する。解析条件は以下の通りとする。

- モデルの支持条件は柱脚でピン支持とし、H 形断面のブレースを強軸方向に設置する。
- ブレースの座屈と塑性化については考慮しない。
- 梁部材に生じる応力を算出するため、剛床仮定を与える代わりに梁部材の軸方向剛性を通常の 10 倍に設

定して解析を行う。

- 基礎梁の剛性は他部材と比較して非常に大きな値に設定する。
- 剛床を設定しないため、荷重は図 5 に示す通り各階の柱梁接合部に与える。




図 5.5 層 3 スパン骨組

3.2. 最適化問題

骨組内の各構面と 5 種類のブレース配置の組合せについて、以下の最適化問題を解く。なお、「部材応力」は軸方向応力と曲げ応力の和から求めた、梁および柱に生じる最大応力である。

目的関数：部材応力 $\sigma_{\max}(x)$ の最小化

制約条件：層間変形角 $r_{\max}(x) \leq 0.005$

なお、1 つの層にブレースを設置可能な構面は 2 つまでとし、近傍解生成時に変更する変数は 5、近傍数は 15、ステップ数を 1000 とする。また、 t の閾値を更新するためのパラメータ ΔF は 10N/mm^2 とする。

表 1: 部材断面および設計用地震力

Floor	Beam (SN400B)	A (cm ²)	Iz (cm ⁴)	Floor	Column(BCR295)	A (cm ²)	Iz (cm ⁴)
R	H-346×174×6×9	52.45	11000	5	□-350×350×9	122.8	23800
5	H-350×175×7×11	62.91	13500	4	□-350×350×9	122.8	23800
4	H-396×199×7×11	71.41	19800	3	□-350×350×9	122.8	23800
3	H-396×199×7×11	71.41	19800	2	□-350×350×9	122.8	23800
2	H-400×200×8×13	83.37	23500	1	□-350×350×9	122.8	23800
1	H-400×200×8×13	83.37	23500	Brace	H×250×125×6×9	36.97	3960

Floor	C_0	Z	T [s]	Rt	W_i [kN]	ΣW_i [kN]	α_i	A_i	C_i	Q_i [kN]	ΣQ_i [kN]
R	0.2	1.0	0.60	1.0	1296	1296	0.23	1.79	0.36	465	465
5					1080	2376	0.42	1.48	0.30	702	1167
4					1080	3456	0.62	1.28	0.26	887	1589
3					1080	4536	0.81	1.13	0.23	1026	1913
2					1080	5616	1.00	1.00	0.20	1123	2149

表 2. 最適化における計算時間の比較

		通常の SA	SVM(S1)	SVM(S2)	二分木(S1)	二分木(S2)
学 習	データ作成時間	---	2175 sec.	2175 sec.	2175 sec.	2175 sec.
	学習時間	---	51.88 sec.	14.38 sec.	20.20 sec.	18.69 sec.
最 適 化	予測の合計時間	---	1976.39 sec.	1008.02 sec.	601.90 sec.	536.62 sec.
	解析回数	103124	65328	63703	60303	60305
	最適化時間	18013.13 sec.	14681.44 sec.	12976.79 sec.	12455.54 sec.	11283.40 sec.
学習と最適化の合計時間		18013.13 sec.	16960.2 sec.	15180.55 sec.	14670.94 sec.	13495.78 sec.
目的関数		74.02 N/mm ²	74.02 N/mm ²	74.02 N/mm ²	74.02 N/mm ²	74.07 N/mm ²




図 6. 最適化結果

3.3. 学習方法

上位 10%を優良解，下位 10%を非優良解とし，以下の S1, S2 の 2 つの条件で機械学習を行う。

S1: 畳込みを行うがプーリングを行わない

S2: 1, 2, 3 層および上層 (4, 5 層) それぞれにフィルターのパターンが含まれれば 1, 含まなければ 0

3.4. 最適化結果

通常の SA および機械学習を用いた SA による最適化の結果をそれぞれ表 2 および図 6 に示す。

図 6 に示す通り，S2 を使用した二分木以外ではすべて同一の解が求まっており，いずれの結果においても目的関数は約 74N/mm²程度になっていることから，精度を損なうことなく最適化を実行できていることが分かる。

全体の学習時間を比較すると，予測に要する時間が長い SVM に次元数の大きい S1 を用いた場合でも約 1000 秒程度の削減ができており，二分木で S2 を用いた場合では 4500 秒程度の時間削減を可能にしている。

S1 および S2 を比較すると，二分木では大きな差異はないが，SVM では S1 の予測時間が S2 の予測時間の約 2 倍になっており，SVM の predict に要する時間は次元数に大きく依存していることが分かる。

4. 結

本研究で得られた成果は以下のようにまとめられる。

1. ブレース配置最適化において，二分木または SVM による学習を最適化アルゴリズムに組み込むことにより，最適化の精度を維持して解析時間を削減する

ことが可能である。

2. とくに SVM を用いた学習では，畳み込み処理を行った解に対してプーリングを実行しデータの次元数を削減することにより，解の優劣の予測に要する時間を短縮することができる。

謝辞

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

【参考文献】

- 1) 福島幸太郎 大崎純 見上知広 宮津裕次: さまざまな形状のユニットで構成された耐震補強ブロック壁の組合せ最適化, 日本建築学会構造系論文集, Vol 81, No. 728, pp. 1657-1664, 2016
- 2) 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, 日本機械学会, 第 12 回最適化シンポジウム, 2016.
- 3) 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最適ブレース配置の分析, 平成 29 年度日本建築学会, 近畿支部研究発表会, 2017.
- 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のブレース配置の組合せ最適化, 平成 29 年度日本建築学会, 全国大会, 2017.
- 5) 中川裕志 著 東京大学工学教程編纂委員会 編: 機械学習, 丸善出版, 2015
- 6) Open System for Earthquake Engineering Simulation (OpenSees), PEERC, UC Berkeley. <http://opensees.berkeley.edu/>, September 23, 2016.

- *1 京都大学 大学院生
- *2 京都大学 教授・博士 (工学)
- *3 首都大学東京 准教授・Ph. D