

建築構造設計のための機械学習

Machine learning for structural design of building frames

大崎 純

はじめに

建築構造物の構造設計の過程は、与えられた材料を用いて、設計条件を満たす最も望ましい解（節点位置、部材配置や部材剛性）を求める問題として定式化される [1]。設計条件の中で、建築基準法やさまざまな規準で指定されて満たさなければならない力学的条件は、設計問題において制約条件（hard constraint）として定式化される。設計荷重に対する変形や応力に関する条件は数式で表現できるので、節点位置や部材断面積を変数とした最適化問題を解いて、制約条件を満たす解（許容解）を得ることができる。一方、設計において考慮することが望ましい非力学的制約や、材料や施工のコストなどの制限値が曖昧な設計条件（soft constraint）は、最適化問題の制約条件として定式化するのが難しく、設計の評価指標と考えて多目的最適化問題の目的関数の 1 つとするのが望ましい。構造設計は、このようなさまざまな設計条件や評価指標を考慮して、最も望ましい解を見出す過程であり、構造設計者の知識や経験が重要な役割を果たす。一般に知識や経験を数式で表すことは困難であるため、機械学習を有効に用いることができる。

機械学習は人工知能（artificial intelligence, AI）の基礎となる技術であり、構造最適化への適用については、以下のようなアプローチが考えられる。

1. 弾塑性解析や時刻歴応答解析などの多くの計算量を必要とする構造解析によって得られる応答量を予測するために、機械学習を用いる。この方法は、1990年代からニューラルネットワーク（artificial neural network, ANN）を用いて行われてきた応答予測や、構造最適化で用いられる応答曲面法や Kriging による応答近似モデル（surrogate model）と同様である。最近になって、多層ニューラルネットワーク（deep neural network, DNN）や畳込みニューラルネットワークが実用化され、再度注目されるようになった。
2. 遺伝的アルゴリズム（genetic algorithm, GA）や焼きなまし法（simulated annealing, SA）などの発見的最適化手法において、構造解析を実行すべき（あるいは実行する必要がない）解を選択するために、機械学習を用いて特徴分析を行う。この方法は、2000年頃から実用化されているデータマイニングでのクラスやカテゴリーの分類問題を解く方法と同様であり、二分木、サポートベクターマシン（support vector machine, SVM）、相関ルールなどを用いることができる。これらの学習方法は、教師あり学習に分類される。データマイニングはビッグデータ処理の基礎となる方法であるが、最近では AI の枠組みで議論されることが多い。
3. 最適化アルゴリズムを用いず、機械学習のみによって最適化する。例えば連続体のトポロジー最適化問題において、最適解の一般的な特徴を学習できれば、個別の荷重条件や構造規模（有限要素分割数）に対応する最適化問題の解を学


習せず、一般の荷重条件や構造規模の最適化問題の解を求めることができる。しかし、一般の最適化問題の解の特徴が、限られた数の最適解に含まれているわけではないので、教師あり学習に分類される手法をこのレベルで適用することは極めて困難である。一方、構造設計の過程を逐次的な意思決定プロセス（マルコフ決定過程, Markov decision process, MDP）としてモデル化して強化学習（reinforcement learning, RL）を用いて学習することも可能である。RLは一般に教師なし学習に分類され、ロボットの制御で実用化されている。また、DNN やモンテカルロ木探索と組み合わせて、囲碁などのゲームの分野で画期的な成果を挙げている。

以上のように、機械学習の利用にはいくつかの方法（レベル）があり、構造最適化において適用されている機械学習の手法のほとんどは、従来から知られている関数近似やデータマイニングなどの手法である。

最近になって、ディープラーニングと強化学習の発展により、画像処理、テキスト・音声処理、ゲームなどの分野で、AI が画期的な成果を挙げている。その他の分野で AI や機械学習を効果的に利用するためには、上記の問題と類似の形式に問題を変換することが重要である。構造最適化では、連続体のトポロジー最適化において、画像処理と同様の方法が提案されている。しかし、建築構造の最適化では、画像としての問題設定が困難であるため、独自の方法が必要である。

機械学習と焼きなまし法を用いた鋼構造骨組のブレース配置の最適化

トラスや骨組の最適化において、部材断面のみならず、部材の配置を最適化することを、トポロジー最適化という [1, 2]。トラスのトポロジー最適化は、断面積最適化の一部と考えることもでき、トラスの断面積を最適化し、断面積が 0 になった部材を削除すれば、最適トポロジーが得られる。しかし、応力制約を考慮する場合は、除去された部材では応力制約が存在しないため、許容領域が不連続になり、最適化が極めて困難になる。このような制約を、設計依存制約条件という。例えば、図 1(a) のような骨組に水平荷重を作用させて、応力制約を与えて最適化すると、図 1(b) のような部材配置が得られる [3]。



(a)

図 1：骨組の応力制約を考慮したブレース配置最適化




図1：骨組の応力制約を考慮したブレース配置最適化

このような不連続性をもつ最適化問題は、GAなどの発見的手法を用いて解くことができる。しかし、中規模以上の建築骨組ではブレース配置の組合せ数は膨大になり、最適化の際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用いる必要がある。本節では、平面骨組のブレース配置最適化における計算量低減のために機械学習を用いる著者らの研究を紹介する [4 – 8]。

例えば図2のような水平荷重が作用する骨組の耐震改修の過程を考えて、ブレースを設置したときの梁と柱の付加応力が最小になるような配置を求める。図3に示すような5種類のブレース（ブレースなしも含む）を考え、各構面に配置するブレースの種類を変数とし、層間変形角の最大値に上限値を与える。また、1つの層にブレースを設置可能な構面は2つまでとする。




図2：5層3スパン骨組




図3：ブレースの種類

骨組の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るSAを用いる。SAによる最適化では、近傍解の評価のために多数回の構造解析を実行する必要がある。したがって、機械学習を用いることにより、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構造解析を行わないようすれば、最適化に要する時間を削減できる。

まず、変数をダミー変数を用いて2値化する。すなわち、構面*i*の5種類のブレースを表す変数 x_i を、0-1変数に変換し、それらのうち1つは1であり、他の4つは0とする。ところで、ブレースの配置を定める際には、その構面単独ではなく隣接する構面との関係が重要である。そのため、図4に示すようなフィルターを用いて畳込み処理を行う。縦方向、横方向、斜め2方向、合計4方向のブレースの組合せをそれぞれ1つのフィルターとして用意する。ブレースの種類は「ブレースなし」も含めると5種類なので、フィルターの種類は $5 \times 5 \times 4 = 100$ 種類であり、15構面に対して合計1500個のフィルター変数（特徴量）が存在することになる。フィルターと一致する組合せが存在する箇所には1を、存在しない箇所には0を与えて、1つのフィルターにつき15個の特徴量を抽出する。画像処理と同様に、プーリングを用いて変数の数を削減することも可能である。この問題では、同一層の3つの構面の変数を1つの変数に削減することができる。しかし、梁と柱の応力はスパン方向のブレースの位置に大きく依存するため、このようなプーリング処理は有効ではない（詳細は文献3を参照）。

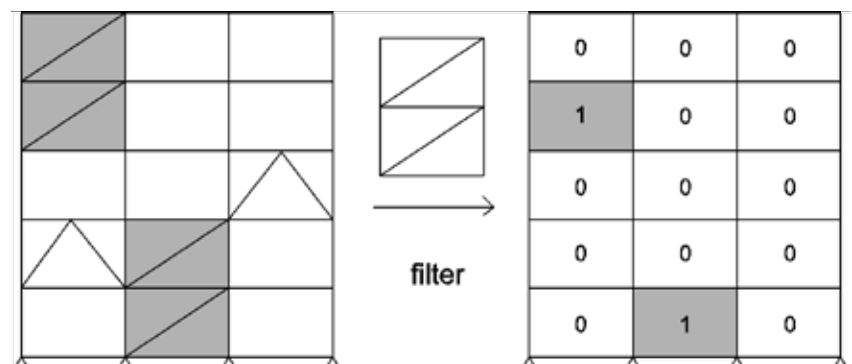




図4：畳込み演算のイメージ

学習のため、10000 個の許容解をランダムに発生し、上位 1000 個を優良解、下位 1000 個を非優良解として SVM および二分木を用いて学習する。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 1 および図 5 に示す [4]。機械学習を用いて得られた最適解の目的関数値は、SA のみの場合と比べて少し大きいですが、ブレース配置の傾向は、図 5 に示す通り類似している。学習と最適化に要する合計の計算時間は、SVM と二分木ともに、SA のみの場合の 2/3 程度となっている。以上より、機械学習を用いることにより、少ない計算時間で近似最適解が得られることがわかる。



通常の SA



SVMを用いた SA
図 5：最適化結果

		通常の SA	SVM	二分木
学習	データ作成時間	---	2093 sec.	2093 sec.
	学習時間	---	12.4 sec.	6.1 sec.
最適化	予測の合計時間	---	483.7 sec.	360.5 sec.
	解析回数	67368	35710	27819
	解析時間	14314.3 sec.	7961.6 sec.	7162.6 sec.
学習と最適化の合計時間		14314.3 sec.	10550.7 sec.	9622.2 sec.
目的関数		84.83 N/mm ²	87.08 N/mm ²	87.51 N/mm ²

表 1：最適化における計算時間の比較

ところで、最適化の対象とする骨組それぞれについて学習するのは効率的ではなく、小規模の骨組で学習した結果を大規模な骨組に対して用いることができれば効率的である。分類問題に対する機械学習の精度は、偽陰性 (FN, false negative) および偽陽性 (FP, false positive) の割合によって評価される。ブレース配置の最適化問題では、FN は優良解を非優良解と判断した場合、FP は非優良解を優良解と判断した場合であり、近似最適解を求めるためには、優良解を見逃してしまうような FN が小さいことが望ましい。5 層骨組を SVM を用いて学習した結果を用いて 10 層骨組の解の優劣を予測したとき、FN および FP の数はそれぞれ 178 個および 181 個である。10 層骨組に対して学習を実行して予測した場合、FN および FP はそれぞれ 135 個および 133 個であり、それぞれの差は、優良解および非優良解の数 (1000 個) の 5% 以内である。したがって、高い精度で予測できていることがわかる。

SA を用いて 10 回最適化を行った中で最も良い結果を図 6 に示す。ここで、機械学習を用いた場合と用いない場合で同一の解が得られている。10 層骨組の解析回数 (学習のための解析を含む) は、SA のみでは 223840 回、5 層の学習結果を用いて予測した場合 147737 であり、35% 程度削減できている。以上より、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・非優良解を予測して最適化を効率化できることがわかった。




図 6：10 層 3 スパン骨組の最適解

まとめ

近年のディープラーニングの画期的な成果により、建築でも AI の適用研究が行われている。しかし、AI で成果が得られたのは、画像処理、テキスト処理、ゲームなどの一部の分野であり、その他の分野では、従来の関数近似や分類のような従来から存在する機械学習の手法の適用にとどまっている。しかし、建築の設計行為が、設計者が過去に経験した、あるいは学んだパターンで構成されるデータベースから、最も望ましいものを選択する行為と考えられるならば、建築の構造設計に機械学習の手法を有効に用いることができる。また、構造設計者の思考過程を強化学習によって学習できれば、構造設計ロボットの開発も夢ではない。しかし、大局的な判断をすることが設計行為の本質であるとするれば、構造設計者の役割が失われることはなく、逆に煩雑な計算から解放されて、真の意味での設計行為に専念することが可能となると期待される。

このような観点から、建築構造設計では、ディープラーニングのような高度で複雑な AI ではなく、小規模な応答予測や分類問題に対して機械学習のさまざまな手法を適用することを検討するのが望ましい。例えば、構造最適化は 30 年前は特殊な手法であったが、現在は 3D-CAD とも連携して簡便に利用できるようになった。機械学習についても、数 10 年後には、最適化と同様に、建築のさまざまな分野で設計者や技術者をサポートするための簡便なツールとして有効に利用されるものと期待される。

<参考文献>

- 1.M. Ohsaki, Optimization of Finite Dimensional Structures, CRC Press, 2010.
- 2.T. Hagishita and M. Ohsaki, Topology mining for optimization of framed structures, Vol. 2(3), pp. 417-428, 2008.
- 3.萩下敬雄, 大崎 純, 発見的手法と非線形計画法の統合による離散構造の位相最適化, 日本建築学会構造系論文集, Vol. 73(633), pp. 1959 - 1965, 2008.
- 4.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.
5. 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, 日本建築学会近畿支部研究報告集, Vol. 59, 構造系, pp. 585-588, 2019.
6. 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), B1, 2018.
7. 大崎 純, 機械学習に関する基礎から応用, 機械学習と深層学習, 第3回知的情報処理技術習得セミナー, 日本建築学会・情報システム技術委員会, 知的情報処理技術応用小委員会, pp. 1-13, 2018.
8. 大崎 純, 構造最適化のための機械学習, 第3回デザイン科学数理知能シンポジウム: デザインの実装, 日本建築学会・情報システム技術委員会, デザイン科学数理知能小委員会, pp. 51-58, 2019