

強化学習済み AI の再利用による板厚を 設計変数とした構造最適化

Structural optimization with plate thickness as a design variable by reusing reinforcement-trained AI

渡邊 良太¹⁾, 野波 諒太²⁾

Ryota Watanabe and Ryota Nonami

1) 呉工業高等専門学校 プロジェクトデザイン工学専攻 学生 (〒737-8506 広島県呉市阿賀南2丁目2番11号,

E-mail: s24-zjue@kure.kosen.ac.jp)

2) 博(工) 呉工業高等専門学校 機械工学分野 准教授 (〒737-8506 広島県呉市阿賀南2丁目2番11号,

E-mail: r-nonami@kure-nct.ac.jp)

Lightweight design is required in transportation equipment to improve fuel efficiency. Since manual design is complex, computer-assisted automatic optimization is being used. In particular, optimization using reinforcement learning (RL), an AI technology, is attracting attention. Since AI trained with RL is specialized for structural optimization, it is assumed that even models with modified dimensions can be reused. If reusability is possible, the number of FEM analyses required for optimization can be reduced. Therefore, in this study, the effect of reusing reinforcement learning AI in structural optimization was verified using the optimization of a cantilever beam and a hat beam. In the optimization of cantilever beams, the number of FEM analyses was reduced by about 47% on average. For hat materials, the number of calculations was reduced by an average of 51%. The results showed that the reuse of reinforcement learning AI can reduce the time for structural optimization.

Keywords: Deep Reinforcement Learning, Double Deep Q Network, Optimization

1. 緒言

自動車や航空機等の輸送用機器は燃費向上のために軽量であることが望ましい。人手での設計は困難なためコンピュータによる自動的な最適化に関する研究が盛んに行われている。近年では発展の著しいAIの一種である強化学習 (Reinforcement Learning 以下 RL) を用いる構造最適化が注目されている。Junhyeon ら^[1]は RL を用いた構造最適化を行っている。RL を用いた構造最適化の特徴として最適化過程で AI が最適化手順の学習を行うという点が挙げられる。この強化学習済 AI は最適化対象の構造最適化に特化しており、変数に含まれていない外形寸法を変更したモデル、例えば図 1 に示すように板厚最適化において板厚を設計変数とするがその際変数に含まれていない板の長さを変更したモデルへの再利用が可能ではないかと推察される。もし、再利用が可能であれば板の長さの変更後の最適化時間を大幅に短縮することが可能となる。しかしながら、RL によって作成された強化学習済 AI を外形形状の異なる対象に適応して再利用した場合の最適化時間の短縮効果はほとんど検証されていない。そこで本研究では、一度最適化を行ったことにより最適

化過程を学習した強化学習済 AI の再利用によって、構造最適化のために必要な FEM 解析回数を削減可能であることを示し、強化学習の構造最適化への適用の有用性を検証する。そのために片持ち梁と自動車でよく用いられるハット材を最適化対象として使用する。

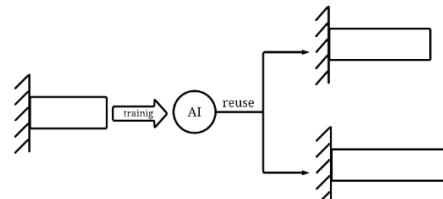


図 1 強化学習済み AI の再利用

2. DDQN による板厚最適化手法

RL は自動的に行動を選択する AI である。本研究の最適化では RL アルゴリズムのなかでも DDQN を採用する。DDQN は囲碁を学習させ勝率が 99.8% を出す^[2]など非常に性能の高いアルゴリズムである。本章では DDQN を使用した板厚最適化アルゴリズムについて述べる。

2.1 片持ち梁モデル

対象とする FEM モデルは図 2 に示すように Shell 要素で構成されており、長手方向に任意の個数 n に分割した。最適化の目的関数は質量最小化とし、制約条件を最大変位量とする。この最適化の設計変数は各領域の板厚 T_1 から T_n と定義する。

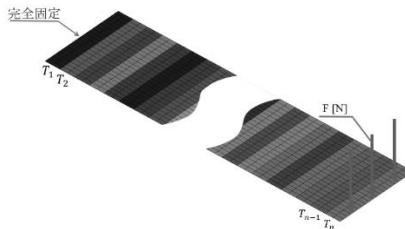


図 2 片持ち梁モデル

2.2 DDQN による板厚最適化手順

2.1 で設定したモデルを DDQN を用いて板厚最適化する手順を図 3 に示す。このフローは episode ループと step ループの二重ループで構成されており、以下[1]~[7]に手順を詳細に述べる。

[1]初期設計案の作成

T_1 から T_n に初期板厚 T_{ini} をもった設計案を作成する。

[2]FEM 解析の実行と結果の取得

状態 s_t は各領域の板厚 T_n と最大変位 $disp$ そして現在の構造物全体の質量 W_p を用い初期板厚 T_{ini} と変位制約条件値 $disp_c$ 、初期の構造物全体の質量 W_{ini} を基準に算出される。 s_1 から s_n は各領域の板厚を観察するが目的関数が最小質量のため式(1)に示すように各領域の板厚の初期質量 V_{ini} を基準に現在の各領域の板厚の質量 V_n を用い算出する。

$$s_n = \frac{V_n - V_{ini}}{V_{ini}} \quad (1)$$

s_{n+1} には最大変位を観察するため式(2)のように変位制約条件値 $disp_c$ を基準に最大変位 $disp$ を用いて算出する。

$$s_{n+1} = \frac{disp - disp_c}{disp_c} \quad (2)$$

s_{n+2} には全体の質量を観察する。式(3)に示すように初期の構造物全体の質量 W_{ini} を基準に現在の構造物全体の質量 W_p を用い算出する。

$$s_{n+2} = \frac{W_p - W_{ini}}{W_{ini}} \quad (3)$$

そのため状態 s_t の算出に必要な最大変位の取得のため本研究では汎用構造解析ソルバーである LS-DYNA を使用して FEM 解析を実行する。

3.Q 値の導出

図 4 に示すように[2]で定義した状態 s_t を Q ネットワークに入力し、行動の数と同一の Q 値を得る。行動 a_t は表 1 に示すように各領域の板厚について増加、減少させる計 $2n$ 個の行動を $a_1 \sim a_{2n}$ として定義する。Q ネットワークは、入力層、出力層の他に 3 層の中間層で構成されている。それぞれ node 数が 128、損失関数は huber 関数、入力層と中間層の活性化関数は swish 関数、出力層の活性化関数は linear 関数で設定されている。得られた Q 値のなかで最大の値をとる行動 a_t を選択する。

表 1 行動の選択肢

| 領域 | 板厚変更 | 行動 |
|-------|------|------------|
| T_1 | 増加 | a_1 |
| | 減少 | a_2 |
| ⋮ | | |
| T_n | 増加 | a_{2n-1} |
| | 減少 | a_{2n} |

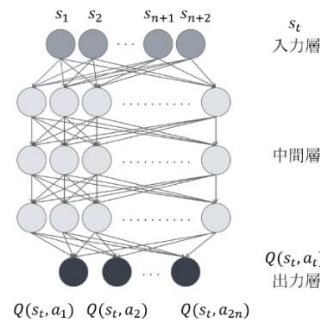


図 4 Q ネットワーク

4.設計案の変更

[3]で選択した行動に従って設計案を変更する。通常のアルゴリズムでは図 5 のように変更後の設計案が上限もしくは下限を超える場合、報酬を -1 を与え元の状態 s_t に戻していた。しかし状態 s_t がこれが step ループが終了するまで繰り返されるため、経験データベースが同じ行動と報酬 -1 で占有され下で述べる学習時に同じデータを大量に学習し非効率である。そこで本検証では変更後の設計案が上限もしくは下限を超える場合、その行動を取りやめ 2 番目に Q 値が高い行動をとるという手法に変更した。

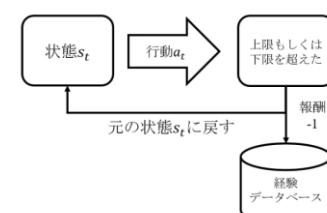


図 5 上下限値を超えた場合の処理

本研究の最適化では制約条件付きでの質量最小化を目

的とする。DDQN を含む強化学習では報酬の設定によって性能が大きな影響を受けるため、適切な報酬設定を行う必要がある。本研究の最適化における報酬を表 2 に示す。想定される報酬の Case は制約条件の満足と不満足、質量の増加と減少をそれぞれ組み合わせた 4 つとなる。それぞれの報酬は表 2 と設定する。Case1 ではこの最適化において最も良い状態となるため式(4)を用い質量の減少量に合わせて報酬を与えるようにした。

$$r = -1 \times \frac{W_p - W_{ini}}{W_{ini}} \quad (4)$$

Case2 では制約条件を満たさない状態が続いてしまうため、最低報酬である-1 を与える。Case3 では質量増加をある程度許容する必要があるが、制約条件を満たさないまま荷重点付近など変位量にほとんど影響のない領域の板厚を増加させ続けることを防ぐため、同じく最低報酬である-1 を与える。Case4 では制約条件を満たすために質量増加を許容する必要があるが最適化の目的に反するため-1 とする。

[3]で決定した行動によって変更した板厚での状態 s_{t+1} を算出するため再び FEM 解析を行いその結果から状態 s_t を更新し、報酬 r_{t+1} を算出する。

表 2 設定報酬

| | | 報酬 |
|-------|--------------|---|
| Case1 | 質量減少・制約条件満足 | $-1 \times \frac{W_p - W_{ini}}{W_{ini}}$ |
| Case2 | 質量減少・制約条件不満足 | -1 |
| Case3 | 質量増加・制約条件不満足 | -1 |
| Case4 | 質量増加・制約条件満足 | -1 |

[5]経験の保存

この状態 s_t 、行動 a_t 、状態 s_{t+1} 、報酬 r_{t+1} をデータベースに保存する。このデータは[7]の学習時に用いられる。その後、次の step に移行し、[2]～[5]の手順を繰り返す。

[6]Q ネットワークの学習

step ループ終了後、式(5)に定義する TD 誤差を算出し学習を行う。この TD 誤差をゼロに近づけるように学習させることで正しい Q 値を算出できるように Q ネットワークを学習させる。

$$TD_{error} = \{r_{t+1} + \gamma \max Q(s_{t+1}, a_{t+1}) - Q(s_t, a_t)\}^2 \quad (5)$$

[7]エリート設計案の保存

通常の DDQN では図 6 に示すように episode ごとに初期設計案に戻っている。この場合、1 回の episode ループで初期設計案から最適解にたどり着くために step 数を多くする必要があり効率が悪い。そこで本研究では図 7 で示すように episode ごとに制約条件を満たした上で目的を

達成した良い設計案を保存しそれを新たな初期設計案として次の episode に移行するエリート保存を提案する。

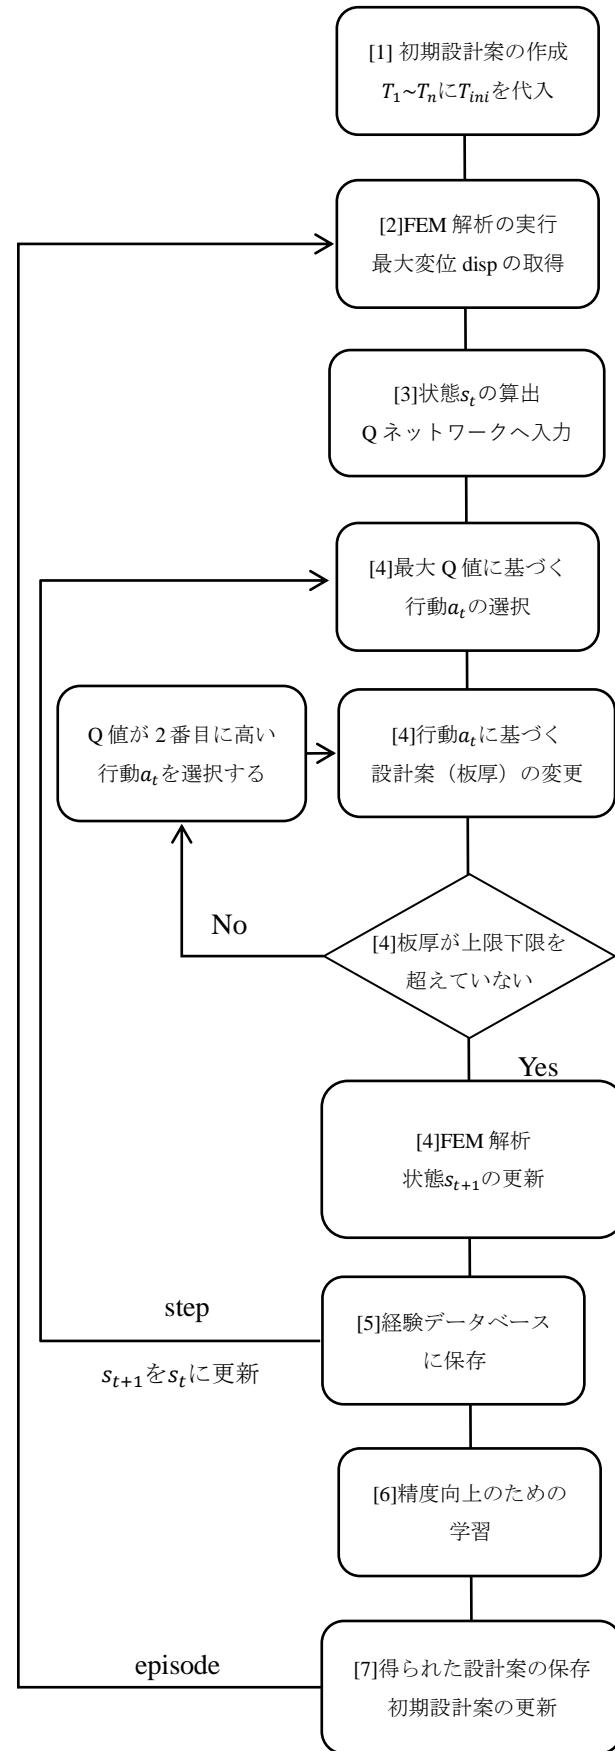


図 3 DDQN による板厚最適化フロー

このエリート保存をすることで最適解近傍から step ループによる探索を始めるため、最低限での step 数での最適化が可能となる。エリート保存後は以降同じ計算を繰り返す。

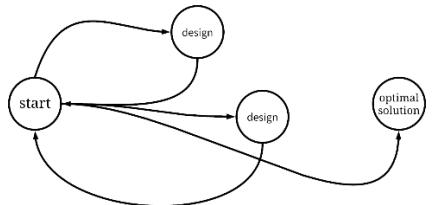


図 6 エリート保存なし

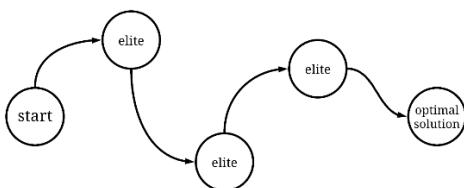


図 7 エリート保存あり

2.3 最適化結果

2.2 で示したアルゴリズムを用い最適化を行った。分割した領域数は 20 個、初期板厚 T_{ini} を 2.0mm、制約条件は 0.3mm とする。板厚最適化モデルの形状・境界条件は図 8 に示す。材料は鉄を想定しヤング率 210GPa、ポアソン比 0.3 とする。長手方向の長さが 300mm のモデルで最適化を行う。最適化によって得られた設計案を表 3 に示す。固定端から自由端にかけて徐々に板厚が小さくなっている。妥当な板厚分布に従っているため、適切な設計案を得られることが示された。また、episode ごとの質量の変化の履歴を図 9 に示す。episode 数が増加するごとに質量が減少しており DDQN により適切な最適化が行われていることが確認できる。

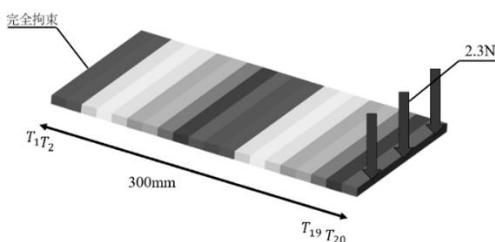


図 8 最適化モデル(片持ち梁)

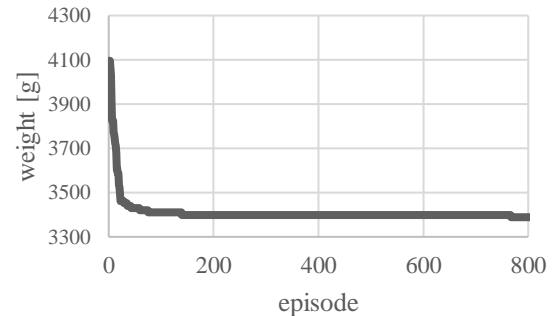


図 9 最適化履歴(片持ち梁)

表 3 300mm の最適設計案

| T_1 | T_2 | T_3 | T_4 | T_5 | T_6 | T_7 | T_8 | T_9 | T_{10} |
|----------|----------|----------|----------|----------|----------|----------|----------|----------|----------|
| 2.2 | 2.4 | 2.4 | 2.1 | 1.9 | 1.9 | 1.9 | 1.9 | 1.8 | 1.8 |
| T_{11} | T_{12} | T_{13} | T_{14} | T_{15} | T_{16} | T_{17} | T_{18} | T_{19} | T_{20} |
| 1.7 | 1.5 | 1.5 | 1.3 | 1.4 | 1.0 | 1.0 | 1.0 | 1.0 | 1.0 |

3. 強化学習済み AI の再利用

本章では強化学習済み AI の再利用による板厚最適化問題の FEM 計算回数の削減効果の検証を行った。再利用ではベースモデルを学習させ(以下 training)，図 10 に示すように学習した AI を training 時から長手方向の長さを変更したモデルの最適化に用いる。

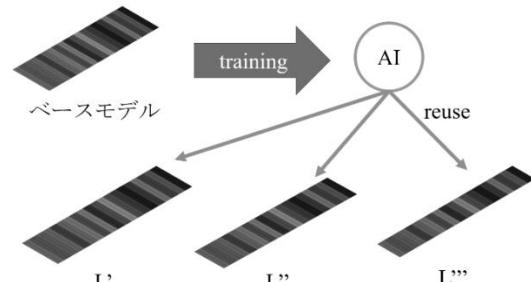


図 10 再利用の流れ(片持ち梁)

3.1 training の手法

3 章で説明したアルゴリズムを用い最適化を行い training 濟の AI を生成するが、エリート保存を用いると図 11 に示すように解析が進むにつれエリート解から最適解までの範囲を学習しており学習範囲が少しづつ狭くなってしまいそのためエリート保存を行わないことによりどの episode も初期設計案から最適化の範囲を学習し適切に training を行える手法とした。しかしエリート保存を行わないことにより episode ループ 1 回で初期板厚から最適解に辿り着く必要があるため step 数を増やす必要が生じた。

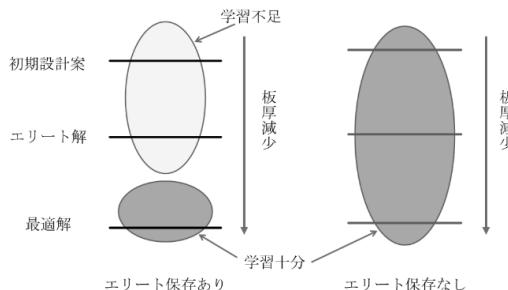


図 11 学習範囲の比較

3.2 教師あり AI による FEM 計算の代用

前節で述べたように training では step 数を増加させる必要があり FEM 計算回数が大幅に増加する。そのため 2.3 で示した最適化よりも長い計算時間が必要となる。そこで training 時に必要な FEM 解析を教師あり AI で代用する方法を提案する。教師あり AI とは教師データとなる入力と対応する出力を学習させ教師データにない入力データから出力を予測させる AI である。本検証では制約条件の判断に最大変位が必要のため入力を各板厚とし出力を最大変位とした教師あり AI を生成する。教師あり AI を使用することで FEM よりも非常に短い時間で最大変位を得ることができる。そのため step 数が増加しても training の計算時間を短縮することが可能となる。教師あり AI の製作には 2 万 5 千の教師データを学習させた。この教師あり AI を用いてランダムに抽出した 4 つ設計案を教師あり AI によって出力された最大変位と FEM で計算した最大変位の比較を図 12 に示す。比較した結果、平均誤差は約 3% であり十分に代用可能といえる。この教師あり AI を用いてエリート保存なしで training を行った。

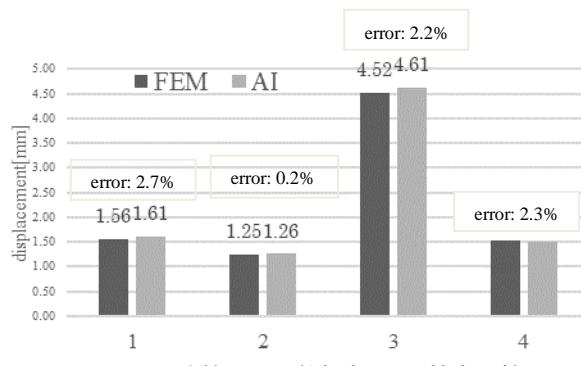


図 12 片持ち梁の教師あり AI 精度比較

3.3 ベースモデルによる片持ちの training

長手方向の長さが 300mm のモデルをベースモデルとして training を行った。training では前節で生成した教師あり AI を FEM の代用として用い最適化を行う。またエリート保存を行わないと step 数を 300 として最適化を行った。training 時の全体質量の履歴を図 13 に示す。約 1200 episode 以降最適解が変動しなくなったため十分な学習が行えたとし学習を終了した。

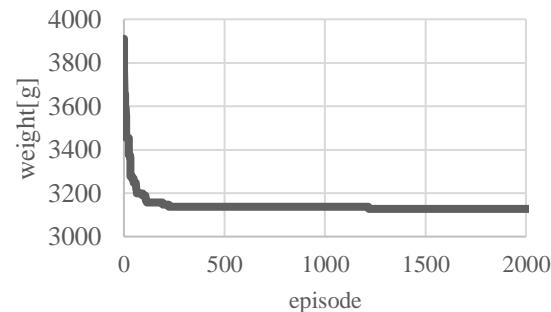


図 13 training 履歴 (片持ち梁)

3.4 強化学習済み AI の再利用による最適化結果

前節で training し生成した AI を長手方向をそれぞれ 305mm, 315mm, 325mm に変更したモデルの最適化へ再利用し検証を行った。なおこの最適化には FEM 解析を用いる。training 時はどの片持ち梁の板厚をどう変更すれば最適解に近づくのかという傾向を得ることが目的であるため教師あり AI の誤差は許容可能だが、実際の最適化では高い精度が求められるため今回は FEM を使用した。305mm, 315mm, 325mm における再利用と training なしの最適解到達時の FEM 解析回数を図 14 に示す。ばらつきはあるものの 305mm では 39%, 315mm では 44%, 325mm では 58% 削減されており平均で 47%，約半分の削減がされていることが確認できる。以上により training 時と長さの異なる対象について、強化学習済み AI の再利用は有効な手法であることが示された。

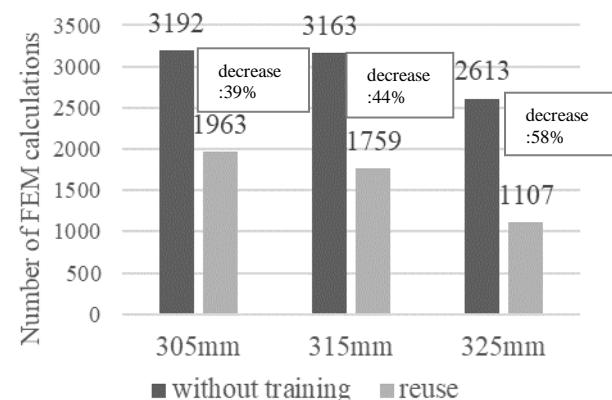


図 14 最適解到達時の FEM 解析回数 (片持ち梁)

4. ハット材最適化問題

前章で片持ち梁最適化問題において強化学習済み AI の再利用が有用であることが確かめられた。この章ではハット材の最適化でも再利用が有用か検証する。

4.1 ハット材最適化モデル

ハット材最適化モデルは図 15 に示す通りである。材料は鉄を想定しヤング率 210GPa, ポアソン比 0.3 とする。初期板厚を 2.0mm とし、制約条件は 1.55mm とする。長

手方向の長さが 400mm のモデルを学習させ 405mm, 410mm, 415mm に再利用し未学習との最適解に到達するまでの FEM 計算回数を比較する。

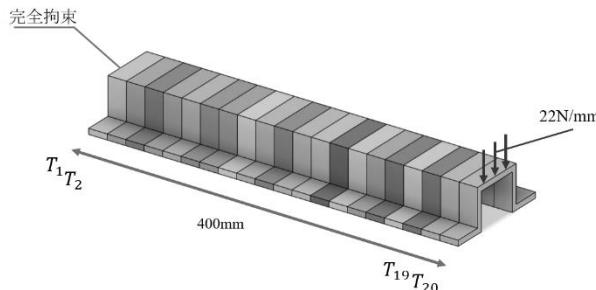


図 15 最適化対象モデル(ハット材)

4.2 教師あり AI の精度検証

ハット材の最適化を学習するために板厚最適化問題と同じようにまず FEM 解析の代用となる教師あり AI を 5 万データを元に作成した。作成した教師あり AI と FEM の比較を図 16 にまとめる。平均誤差は 1% 以下であり板厚最適化問題と同様に十分に代用可能といえる。この教師あり AI を FEM 解析の代用に training を行う。

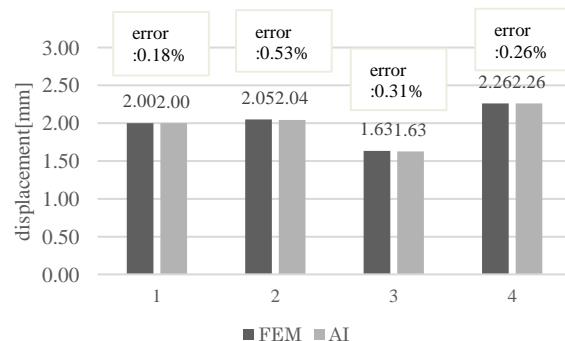


図 16 ハット材の教師あり AI 精度比較

4.3 ベースモデルによるハット材の training

長手方向の長さが 400mm のモデルをベースモデルとして training を行った。 training では前節で生成した教師あり AI を FEM の代用として用い最適化を行う。また片持ち梁と同様にエリート保存を行わなかったため step 数を 300 として最適化を行った。 training 時の全体質量の履歴を図 13 に示す。約 60 episode 以降最適解が変動しなくなったため十分な学習が行えたとし学習を終了した。

4.4 再利用によるハット材最適化

長手方向の長さが 400mm のモデルをベースモデルとして training を行った。この強化学習済み AI を再利用し 405mm, 410mm, 415mm の最適化を行った。405mm, 410mm, 415mm における再利用と training なしの最適解到達時の FEM 解析回数を図 18 に示す。ばらつきはあるものの 405mm では 54%, 410mm では 53%, 415mm では

46% 削減されており平均で 51% 約半分の削減がされていることが分かった。以上によりハット材においても training 時と長さの異なる対象についても、強化学習済み AI の再利用は有効な手法であることが確認できた。

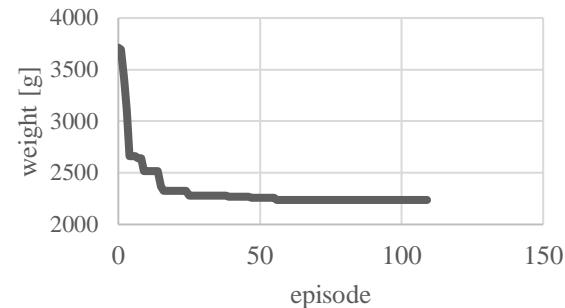


図 17 training 履歴 (ハット材)

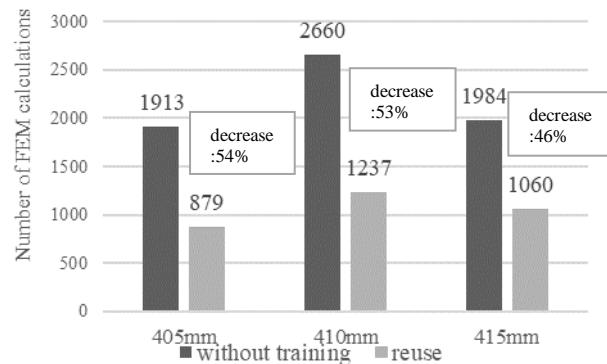


図 18 最適解到達時の FEM 解析回数

5. 結言

本研究では DDQN により最適化過程を学習した強化学習済み AI を再利用して外形寸法を変更した構造物の最適化の検証を行った。この手法により構造最適化のために必要な FEM 解析回数を削減可能であることを示すため、強化学習の構造最適化への適用の有用性を片持ち梁とハット材をモデルとして使用し検証した。結果として片持ち梁においては平均で約 47% の計算回数の削減ができた。ハット材においては平均で約 51% の計算回数の削減ができた。したがって学習済み AI の再利用によって最適化時間を短縮することは可能であり、外形寸法を変更した構造物の最適化への適用は有用であることが示された。本研究では板厚最適化のみを行ったため今後は板厚最適化以外の最適化でも再利用が有用か検証する。

参考文献

- [1] Junhyeon Seo and Rakesh K. Kapania, AIAA: 1692, 2021
- [2] SILVER, David, et al. Mastering the game of Go with deep neural networks and tree search. nature, 529.7587: 484-489, 2016