

強化学習を用いた溶接残留応力低減のための 溶接順序最適化システムの開発

Development of a Welding Sequence Optimization System for Reducing Residual Stress in Welding Using Reinforcement Learning

大阪府立大学	里 明起照	Akinobu	SATO	Student-member
大阪府立大学	橋詰 光	Hikaru	HASHIZUME	Non-Member
大阪府立大学	加藤 拓也	Takuya	KATO	Student-Member
大阪府立大学	生島 一樹	Kazuki	IKUSHIMA	Member
大阪府立大学	柴原 正和	Masakazu	SHIBAHARA	Member

Currently, various welding is performed in the process of manufacturing all kinds of structures such as ships and bridges, and metal 3D printers are attracting attention in recent years. However, there are several problems in these manufacturing method. Residual stress occurs inside the products due to thermal processing. It is thought that defects such as cracks during manufacturing, deformation and fatigue fracture are caused by the tensile stress on the surface. Therefore, it is necessary to optimize the construction method as welding orders and to reduce the residual stress on the product surface. However, it is impossible to analyze all welding sequences of multilayer welding because of physical and temporal constraints. On the other hand, research on artificial intelligence has developed recently, and AI which exceeds human ability has appeared. In this research, we aim to construct a system that automatically obtains the optimum the welding sequence in which the residual stress on the product surface decreases by using AI for searching the welding sequence. In this research, we study the learning method for optimizing of the weld sequence based on reinforcement learning and show the possibility of applying AI to optimizing of the weld sequence.

Keywords: Redidual Stress, FEM, Reinforcecment Learning

1. 緒言

現在、船舶、橋梁などのあらゆる構造物の製造過程において溶接が行われており、近年では複雑な形状を比較的容易に製造するのに金属3Dプリンタが注目されている。金属3Dプリンタは発電機のタービンなどの試作や模型実験用のモデル製作、また巨大金属3Dプリンタによる航空、造船業の部品製造などに利用されている。

しかしこれらの製造方法には幾つかの問題も存在している。これらの製造工程では熱加工による残留応力が製品内部に発生する。これによる表面の引っ張り方向の残留応力による製造時の割れ、疲労破壊などの欠陥が生じると考えられている。また残留応力により歪みが発生し、変形による精度の悪化が生じる。そこで施工方法を最適化させ、製品表面の残留応力を低減させることが必

要である。

溶接、造形中の変形を予測する手法として有限要素法 (Finite Element Method : FEM) に基づく熱弾塑性解析を用いる。熱弾塑性解析は、複雑形状の造形中の金属の溶融・凝固に伴う変形や応力の挙動を詳細に予測できることから、構造物の多数の溶接や3Dプリンタによる製品の製造工程における問題解決に対しても非常に有効な手段であると考えられる。しかし多層溶接や3Dプリンタの溶接において全ての条件について解析することは、メモリ消費量および計算時間の制約によって現実的に困難である。

一方近年人工知能 (Artificial Interigence : AI) に関する研究が発展しており、ヒトの作業の変わりにAIを利用しシステムを自動化、高効率化する未来が期待される。

そこで本研究ではI開先多層溶接の入熱順序の探索にAIを用いることで、製品表面の残留応力が低下する最適な順序を自動的に得るシステムを構築することを目的とする。

連絡先: 里 明起照
〒599-8583 大阪府堺市中区学園町 1-1、工学研究科
航空宇宙海洋系専攻 海洋システム工学分野
E-mail: a_sato@marine.osakafu-u.ac.jp

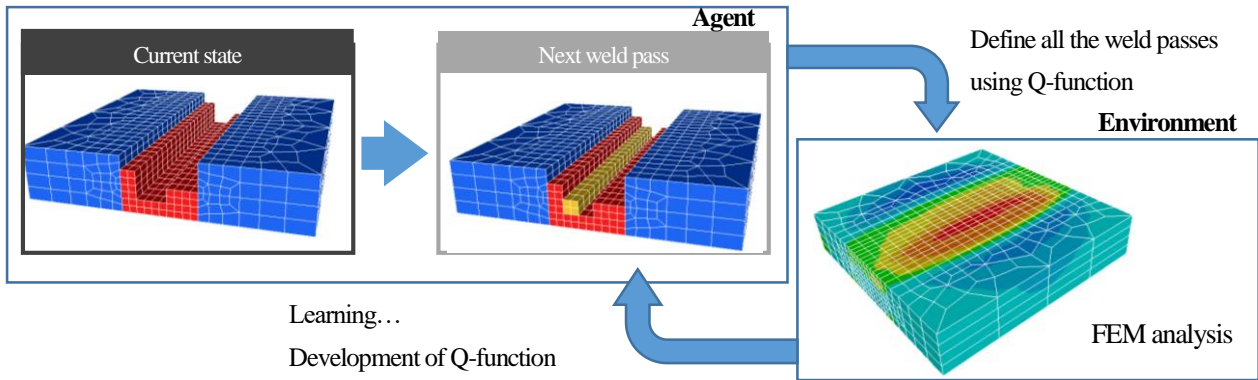


Fig. 1 Analysis flow of the proposed method.

2. 強化学習を用いた入熱順序決定システム

2.1 概要

機械学習には強化学習と言う方法があり、試行錯誤から「価値が最大となる行動」を学習する方法である。強化学習では学習の対象となる「環境」(本システムではFEM解析のモデル)と、(次の入熱パスの選択についての)行動や学習を行う「エージェント」で構成されている。強化学習を用いた本システムの概略図をFig. 1に示す。システムは以下のように3つのセクションに分かれている。

- 1) 現在の環境の状況から次の行動の選択
- 2) 環境の変化の評価
- 3) システムの学習

強化学習のエージェントは環境状態 s から次の行動 a を経た時の評価値 $q(s,a)$ を持っている。(1)では $q(s,a)$ が高い行動を選択しその工程を繰り返すことにより、入熱開始から終了までの順序を決定する。(2)では残留の最終状態から報酬 $reward(s,a)$ として評価し、(3)で選択した行動の評価値 $q(s,a)$ を、報酬 $reward(s,a)$ を用いて更新する。またそれぞれの行動の評価値 $q(s,a)$ の集合を Q 関数と言い今回はテンソルで保持しているが、学習対象が複雑になるとニューラルネットワークで Q 関数を近似する場合もある以下にI開先多層溶接を例にして各セクションを説明する。

2.2 Q関数による入熱順序の決定

本システムでは入熱順序を1パスずつ順に選択することを繰り返すことにより、入熱開始から終了までの順序を決定する。次の入熱パスの選択の概略図をFig. 2に示す。現在の入熱状況 s_i 、各列の入熱回数と最終入熱列 (Fig. 2では入熱回数[3, 1, 1, 2, 2], 最終入熱列:4)から次に入熱する次に入熱する列を決定する。

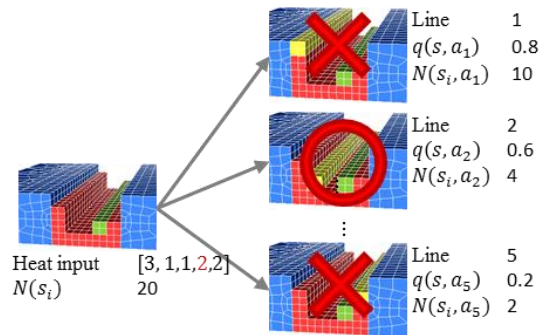


Fig. 2 Selecting the next pass.

次に入熱列の候補 $a_j(j=1, 2, \dots, 5)$ それぞれの評価値 $q(s_i, a_j)$ を Q 関数から参照し、この評価値にバイアスを掛けた値が最大となる入熱列を次の入熱列 a として選択する。このバイアスは実行回数が少ない入熱候補に対して値が大きくなる性質があり、その行動が選択されやすくなる。

$$next\ action = action \left(\max \left(q(s_i, a_j) \cdot \left(1 + \frac{\alpha \sqrt{N(s_i)}}{1 + N(s_i, a_j)} \right) \right) \right) \quad (1)$$

α : 係数
 $N(s_i)$: 状態 s_i になった回数
 $N(s_i, a_j)$: 状態 s_i から行動 a_j を経た回数

2.3 理想化陽解放FEMによる解析と残留応力の評価

前の節で選択した入熱順序を元に理想化陽解法FEMでモデルの残留応力分布の解析を行う。残留応力は要素ごとにテンソルとして格納されているため、このまま残留応力を評価することは難しい。そこで今回は表裏面それぞれの方向の引っ張り応力に対して二乗平均と各方向の応力の最大値の線形和を残留応力分布の評価値としてスカラー化する。さらに残留応力の評価値から強化学習に返す報酬 $reward$ を決定する。

$$\Delta f_i(\text{surface}, x) = s_i(\text{surface}) \cdot \sigma_{xi} \quad (2)$$

$$\text{Mean Square}(\text{surface}, x) = \frac{\sum \Delta f_i(\text{surface}, x)}{n} \quad (3)$$

$$\text{Evaluation} = \sum \alpha_i \cdot \text{Mean Square} + \sum \beta_k \cdot \max(\sigma_j) \quad (4)$$

$$\text{Reward} = \frac{\varphi - \text{Evaluation}}{\omega} \quad (\varphi, \omega : \text{constant}) \quad (5)$$

2.4 システムの学習

システムの学習ではQ関数の更新を行う。入熱順序の選択時にQ関数から参照した全ての評価値 $q(s, a)$ に対して、残留応力の評価で決定した報酬を用いて更新する。これまでの学習の中で状態 s から行動 a を経た時に得られた報酬 $\text{reward}(s, a)$ の平均が更新後の評価値 $q(s, a)$ となる。

$$q(s, a)_n = \frac{N(s, a)_o}{N(s, a)_o + 1} \cdot q(s, a)_o + \frac{1}{N(s, a)_o + 1} \cdot \text{reward}(s, a) \quad (6)$$

$$N(s, a)_n = N(s, a)_o + 1 \quad (7)$$

3. I 開先多層溶接の入熱順序の学習

3.1 解析モデルと条件

強化学習における環境であるFEM解析においてQ関数から選択された入熱順序を元にモデルの解析を行い、得られた結果を元に、エージェントの学習(Q関数の更新)をさせる。本章で用いるモデルをFig.3に示す。鋼板の寸法は幅60mm、縦60mm、高さ12mmである。また溶接部のメッシュサイズは幅2mm、縦3mm、高さ2mmとなっており、モデルの節点数は2960、要素数は3579とした。材料はSM490である。拘束方法は剛体拘束とした。溶接のパス数は幅方向に4pass、高さ方向に5passの計20passとしており、1passの入熱条件は入熱量2250J、速度4.5mm/sec、熱効率0.80である。尚底1層目の入熱が完了した状態から、FEM解析を行いそれ以降の順序を学習の対象とした。

3.2 学習結果

3.2.1 入熱順序

学習で得られた得られたビード部の入熱順序をFig.4に示す。順序としては先に中央ビードを形成した後両端列を交互に入熱する結果が得られた。この結果より裏面の応力を下げるために最後に縦に入熱する傾向が確認で




Fig. 3 Mesh division for FEM.

Table. 1 Heat input condition.

current[I]	voltage[V]	v[mm/sec]	efficient
150	15	4.5	0.7




Fig. 4 Welding order.

きた。一般的な入熱工程では入熱部の拘束が大きくなる終盤に上面への入熱が集中し、それらの冷却時の収縮が上面中央部に起きてしまう。これにより角変形が大きくなり裏面の残留応力が高くなってしまふ。そこで終盤に縦に入熱することにより、冷却時の収縮が上面中央部に集中するのを防いだと考えられる。

3.2.2 学習した入熱順序における残留応力分布

それぞれの学習で得た溶接順序を元に熱弾塑性FEM解析を行った結果をFig.5, 6に示す。モデル上面の溶接線と水平方向の応力に関して、従来の方法、学習結果ともに最終パス部が最も応力値が高くなった。しかし一層ずつ順番に溶接した従来の方法ではビード部全体に引っ張りの応力が確認された。一方学習結果ではビード部の引っ張り応力 σ_x の範囲がわずかではあるが縮小し、最終パス部の応力値も低下した。この応力の低下は加工硬化が原因と考えられる。また、Fig.7, 8に残留応力の二乗和平均と最大値を示す。AIによる入熱順序の残留応力の二乗和平均は従来の入熱順序よりも低下していることがわかる。残留応力の最大値も同様に低下していることがわかる。さらにモデル裏面の残留応力において、学習結果で応力の σ_y 低下が確認された。裏面の残留応力 σ_y が低下した結果については同時に角変形が小さくなることが確認された。

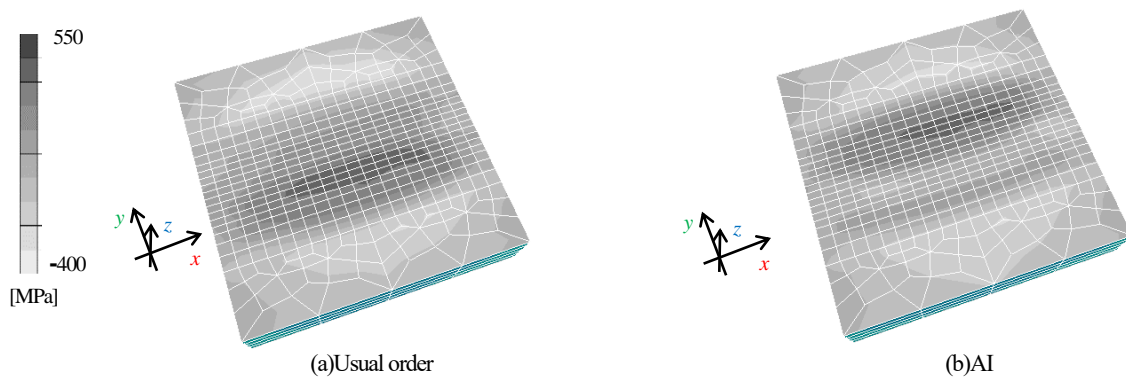


Fig. 5 Residual stress in X on the upper surface.




Fig. 6 Residual stress in Y on the back.




Fig. 7 Mean square of stress.




Fig. 8 Maximum residual stress.

4. 結言

本研究では、AIを用いて入熱順序の最適化について検討した。I開先多層溶接において入熱順序を学習させたところ、両端列を交互に入熱する結果を得た。この結果をもとに理想化陽解法FEMにて入熱をしていくと、残留応力の二乗和平均、最大値ともに低下することが確認され、さらに裏面残留応力 σ_y が大きく低下することが確認された。

これにより残留応力低減のための溶接入熱順序決定に強化学習が有効であることが示唆された。

参考文献

- [1] 松宮大樹, 柴原正和, 生島一樹, 河原充南野寿造: 金属3Dプリンタを用いた積層造形時の熱変形・応力挙動の解析
- [2] David Silver*, Julian Schrittwieser*, Karen Simonyan*, Ioannis Antonoglou, Aja Huang, Arthur, Guez, Thomas Hubert, Lucas Baker, Matthew Lai, Adrian Bolton, Yutian Chen, Timothy, Lillicrap, Fan Hui, Laurent Sifre, George van den Driessche, Thore Graepel, Demis Hassabis : Mastering the Game of Go without Human Knowledge
- [3] 毛利良介, 江端末春: 高速回転アーク溶接方による片面I型突合わせ溶接施工法の開発