

AI を用いた線状加熱方案作成システムの構築

大阪府立大学大学院 ○前川 真奈海, 生島 一樹

野津 亮

ジャパン マリンユナイテッド株式会社

丹後 義彦, 木冶 昇

大阪府立大学大学院

柴原 正和

Development of Planning System for Line Heating Using AI

by Manami MAEKAWA, Kazuki IKUSHIMA, Akira NOTSU,
Yoshihiko TANGO and Noboru KIJI, Masakazu SHIBAHARA

1. 緒 言

船舶の船首、船尾部の外板曲面は巨大かつ複雑な形状をしているため、古くから線状加熱によって作られてきた。それらの曲面形状の多くは椀型・鞍型・捩れ型等の非可展局面であるため、線状加熱によって鋼板に角変形（曲げ）と同時に熱による収縮（絞り）を与えることが必要となる。線状加熱は、ガスバーナーで加熱した際に発生する局所熱応力による塑性変形を利用して曲面形成を行う。一本の加熱線によって生じる固有変形には、横曲り、横収縮、縦曲り、縦収縮があり、これらの変形量は加熱するガスバーナーの移動速度、ガス流量と酸素の流入の混合比、バーナーと鋼板の距離等を変化させて鋼板への入熱を制御することにより変化させることができるが、絞りの量とその結果生じるたわみ量の関係や、入熱量と角変形との関係は非線形であり、予測が大変困難であるため作業者の熟練が必要となる。

加工工程において作業者の経験と勘に頼る部分が多いこと、そのために品質や寸法精度、納期の管理が困難であることが問題となっており、以前よりこれらの問題を解決するために機械化が試みられてきた¹⁾。しかしながら、多数の変動因子を持つ熱と変形の過渡現象は、強い非線形性を伴うために実用速度で計算することができず難渋してきた。

一方、近年人工知能(Artificial Intelligence: AI)の発達に伴い、AI を用いた囲碁プログラム AlphaGO²⁾のように人間の能力を上回るような AI が出現するなど、AI 技術は極めて早く進展している。AI 技術を用いることで、数式化できないような非線形関係あるいは曖昧な特徴量の利用・表現が可能であることが知られており、現在様々な分野への応用が進められている。上記の AlphaGo の事例に代表されるように、シミュレーションと AI の組み合わせによる最適化は極めて親和性が高いため、囲碁等のゲームの代わりに、非線形有限要素法 (Finite Element Method: FEM) をはじめとするシミュレーション技術を採用し、AI と組み合わせることで、製造現場における施工方案最適化のための新しい概念が構築可能と考えた。線状加熱問題においては、AI の持つ非線形現象の特徴把握が可能であるという特性を、加熱条件と変形の間非線形な関係の把握にも応用可能であると考えられることから、この関係を効率的に学習することで最適加熱方案の提案が可能であると考えられる。

本研究では線状加熱において任意形状を得るための最適な入熱条件を得ることを目的に、深層強化学習と線状加熱シミュレーションを統合した AI 線状加熱システムを構築する。本システムでは、まず加熱位置と加熱により生じる変形の間非線形な関係を深層強化学習により十分な学習を行ったのち、加熱により得られる変形が目的形状に最も近づくような加熱位置を選択することで、加熱方案を作成していく。本システムを線状加熱における基本形状である椀型、鞍型、捩れ型の 3 形状作成時の加熱方案作成に対して適用し、本システムの特性および有用性について検討する。

2. AI 線状加熱システムの提案

2. 1 強化学習の概要

本研究では、線状加熱時の加熱位置と変形の間非線形な関係を自動的に学習するシステムを構築するため、学習方法として強化学習を用いる。強化学習とは、試行錯誤の過程から自立的に学習する方法である。強化学習では、一つ一つの事項についての正解不正解は与えず、代わりに出力値に対する報酬を与える事によって、AI 自身が最適な行動を探索しながら学習が進む。本研究では、強化学習の一つである Q 学習³⁾に用いられる価値関数 Q を深層学習によってニューラルネットワークに近似させる Deep Q-Network(DQN)⁴⁾という手法をベースとして用いた。ここで、学習とは、学習に用いた入力・出力間の関係が再現されるように、各層のノード間




Fig. 1 Schematic illustration of developed learning system based on DQN

の重みを調整することを言う。

Fig. 1 に本システムの概要図を示す。強化学習では、“エージェント”が“環境”に対して“行動”をとった際の“状態”の変化から“報酬”を算出し価値関数として学習することから、これらを定義する必要がある。本システムにおいて、環境は線状加熱シミュレーションとし、エージェントにおいて価値関数の学習および行動の選択（探索）を行う。エージェントが選択した行動、すなわち加熱線が環境に渡されると、線状加熱シミュレーションの結果から目的形状との差を算出し、これを状態として更新する。その更新された状態と、以前の状態との差、すなわちどれだけ目的形状に近づいたかを報酬とし、これがエージェントに返される。エージェントは、この“状態”、“行動”、“報酬”の関係を価値関数に学習させる。探索と学習を繰り返すことによって価値関数が“状態”、“行動”、“報酬”の適切な関係を表現できるようになり、価値関数が最大となる行動、すなわちもっとも目的形状に近づく加熱線が選択可能となる。

次節以降、本システムにおけるエージェント、環境、行動、状態、報酬および、これらを用いた一連の加熱方案作成システムの詳細を述べる。

2. 2 線状加熱問題における学習

線状加熱問題において、環境は、線状加熱シミュレーションとして、熱弾塑性解析に比べて計算時間が短い、固有ひずみ法による FEM 弾性解析を採用した。“状態”を解析によって得られた面外方向変位と目的形状との差、“行動”を次の加熱位置として、“報酬”は、選択した行動によってどれだけ目的形状に近づいたかを評価し、加熱前の目的形状との差に対して加熱後目的形状との差が小さくなった場合にはプラスの報酬を、加熱前の目的形状との差に対して加熱後目的形状との差が大きくなった場合にはマイナスの報酬を与える。これらを、エージェントにおいて、入力を“状態”、出力を“行動”に対する“報酬”の期待値として価値関数に学習させる。この際に、入力である状態を分布 (40×40 の 2 次元テンソル) として学習させるため、価値関数 Q を畳み込みニューラルネットワーク (Convolutional Neural Network: CNN) によって近似することとした。また、線状加熱において取りうる行動（加熱線の始点、終点のペア）は無数にあり、これらをすべて学習することは困難であるため、出力である行動に対する期待報酬値は、鋼板の表裏面それぞれの加熱要素に対応する期待報酬値 ($40 \times 40 \times 2$ の 3 次元テンソル) として学習を行う。学習後の CNN から得た出力は、報酬の分布を表現しているので、報酬が高い要素を通る直線を次の加熱線として選択する。これを環境に渡し、行動を実行、すなわち解析を実施する。これによって状態が更新され、終端判定が真でなければ次の行動を選択、という動作を繰り返すことにより学習を進めることで、ある面外変位分布からより目的形状に近づくための加熱位置を得られるシステムを作成する。

CNN の構成について Table 1 に示す。層間でどのように信号を伝播させるかを調整する活性化関数には、出力層以外はシグモイド関数を用いる。畳み込み層②および③では x, y 方向にデータの圧縮を、逆畳み込み層①および②では x, y 方向にデータの拡張を行っている。最適化手法 (CNN の重みの更新方法) として、Adam 法⁵⁾を採用した。また、時系列情報の学習となるため、時間方向の相関が現れることで正常な学習ができな

Table 1 Configuration of CNN

Layer	Dimension	Layer	Dimension
Input	[40, 40, 1]	Deconvolution①	[10, 10, 128]
Convolution①	[40, 40, 32]	Deconvolution②	[20, 20, 64]
Convolution②	[20, 20, 64]	Deconvolution③	[40, 40, 32]
Convolution③	[10, 10, 128]	Output	[40, 40, 2]




Fig. 2 Procedure to select an action

いということを回避するために、Experience Replay 法⁶⁾を採用した。これは、逐次順番に学習するのではなく、 $(state_n, action_n, reward_n, state_{n+1})$ をメモリ上に保存しておき、データが十分蓄積されたときランダムにデータを取りだし学習を行うという手法である。

2. 3 加熱線の選択方法

CNNによって次の行動を選択、すなわち加熱条件を作成する際には、ハフ変換を用いることによって、以下の手順に従い期待報酬値の分布から加熱線形状に変換を行う。ハフ変換とは、画像の中から直線や円などの図形を検出する手法である。また、各工程について Fig. 2 に示す。

- ① 表面、裏面のうち加熱面を選択する。このとき加熱線を選択した場合に得られる報酬の期待値は Fig. 2(a) のように分布として表されている。
- ② 前処理として、プラスの報酬を持つ要素のうち、報酬が下位 70%の要素を 0 に置き換え、これを重み行列として保存する。(Fig. 2(b))
- ③ 重み行列を 2 値化 (Fig. 2(c)) してハフ変換を実行し、連続で指定した点数以上を通る直線を見つける。
- ④ ③で得られた直線のうち、通過する点の座標と重み行列から、報酬が高い点を最も多く通過する直線を見つける。(Fig. 2(d))
- ⑤ ④で得られた直線の方程式において、2 値化後の行列 (Fig. 2(c)) で正の値をもつ区間を、加熱線を表す線分として、始点・終点を決定する。(Fig. 2(d))
- ⑥ ①～⑤を表面・裏面ともにに行い、より高い報酬が得られる方を選択する。

また、学習中は、行動選択（探索）時 ϵ -greedy 法⁷⁾を用いて試行を繰り返す。 ϵ -greedy 法とは、一定確率 ϵ でランダムな行動を、それ以外は価値関数を用いて報酬が最大となるような行動を選択する行動の探索法である。効果的に学習させるため、ランダム行動選択率 ϵ について、学習初期は 0.7 として、最終的に 0.1 になるよう試行回数に比例して変化させる。

2. 4 終端判定の設定

本研究において、1 ケースの打ち切り条件である終端判定は、以下の条件が一つでも成立するかどうかを判定するものとした。終端判定が真のとき、次のケースとして初期形状、すなわち面外変位がない状態から新たに加熱線 1 本目についての解析を実施する。

1. 連続で加熱する加熱線の本数が指定回数(20 本)を超えた場合
2. 加熱前よりも加熱後の方が目的形状との差が十分大きくなったとき
3. 初期形状（加熱なし）よりも加熱後の方が目的形状との差が十分大きくなったとき
4. 目的形状に十分近づいたとき

2. 5 報酬の算出方法

微小変形解析において、変形はそれぞれの加熱線による変形量の足し合わせで表される。そのため、報酬は、加熱を行うごとに受け取る「即時報酬」として加熱線 1 本ごとに式(1)に従い算出し、この値を元に逐次 CNN の学習を行う。

$$R_n = \frac{\sum(d_{n+1})^2 - \sum(d_n)^2}{\sum(d_{n+1})^2} \times 100 \quad (1)$$

ここで、 d_n は n 本目の加熱を行った後の目的形状との差である。上式は $(n+1)$ 本目の加熱によって、 n 本加熱時の状態から、どれだけ目的形状に近づいたかを示す。

一方で、線状加熱による板曲げにおいて、板厚以上の大きな変形を生じさせる場合がある。そのような大きな変形が生じる場合において、面内の収縮による面外変形を解析可能な大変形解析を行う必要がある。大変形解析においては、加熱履歴が変形に影響するため、式(1)によって加熱線 1 本ごとに報酬を算出する方法では、加熱線を正確に評価することができない。したがって、本システムでは Q 学習に基づき、加熱終了時において、最も目的形状に近づくような加熱線の組合せを学習する。Q 学習とは、終端で得られる報酬、すなわち「長期的報酬」を最大化する一連の行動を学習する方法である。そこで、式(2)に示す評価式を元に各加熱線に対応する報酬を算出する。

$$R_n = \begin{cases} \frac{\sum(d_0)^2 - \sum(d_N)^2}{\sum(d_0)^2} \times 100 - 5 & (\text{terminal}, n = N) \\ \gamma \max(Q(\text{state}_{n+1}, \text{action}_{n+1})) - 5 & (\text{not terminal}, n \neq N) \end{cases} \quad (2)$$

ここで、 d_N は終端まで加熱時の目的形状との差、 d_0 は加熱前の目的形状との差である。割引率 γ は 0.9 と設定した。第一項は、終端の加熱線に対しては、複数本加熱を行った結果、すなわち最終形状と目的形状との差から算出した値を与える。一方で終端以外の加熱線に対しては、実際に行動を実行した際に得られる報酬値ではなく、価値関数を用いて推測した現在の状態から得ることのできる最大報酬に割引率を乗算した値を与える。終端以外の場合において、第一項について最大報酬のみを考え簡易的に表現すると、式(3)のように表される。

$$R_n' = \gamma R_{n+1}' = \dots = \gamma^{N-n} R_N' \quad (3)$$

ここで、 R_N は終端で得られる報酬であり、式(2)における終端の場合の第一項に示される式で算出される。これを価値関数に学習させることによって、価値関数から終端において最も高い報酬が得られる行動、すなわち目的形状に最も近づく加熱線を選択できるようになる。

また、第二項に示すように、加熱線 1 本ごとに、加熱本数が多くなるほど全体の報酬が減るように負の値も付与する。これによって、少ない加熱本数で最終的に目的形状に近づく加熱線の評価を行う学習を行う。

以上のように、ある面外変位分布から、より目的形状に近づくための加熱位置を得る AI 線状加熱システムを構築した。本システムを用いることで、目的形状の設定後は、人間の手を介することなく自動で適切な加熱線を探索および学習を行う。これによって、学習が進む（学習ケースが増える）に従い、より適切な加熱線を選択可能になることが期待される。また、本システムの構築は Google 社より提供されている AI 開発用ライブラリ Tensorflow⁹⁾を用いた。

3. AI 線状加熱システムによる加熱方案と評価

3. 1 解析条件の設定

本章では、提案した AI 線状加熱システムに加熱位置と加熱により生じる変形の関係を学習させ、加熱方案の作成を行う。対象の形状は、線状加熱において最も基本的な碗型、鞍型、捩れ型の 3 ケースとした。

固有ひずみを用いた弾性解析⁹⁾では、固有変形を加熱線に沿って固有ひずみとして加えることで変形を予測することができる。Fig. 3 に本章で用いる解析モデルを示す。幅 500mm、奥行 500mm のシェル要素モデルである。要素分割は、幅方向および奥行方向にそれぞれ 40 分割とし、解析対象材料は SM490A と仮定した。解析モデルの四隅のうち 3 点を拘束点として定義し、拘束点において面外変位が 0 となるように目的形状を設定する。解析モデルに対して、加熱線が通る要素に、固有ひずみおよび曲率を与えることで解析を行う。

単一種類のガスをを用いた線状加熱において、固有変形は溶接変形と同様に入熱パラメータ Q/h^2 でおおよそ整理ができると考えられる。そこで、板厚 16mm の 3D モデルに対し、理想化陽解法 FEM¹⁰⁾による熱弾塑性解析を行い、その変形結果を用いて入熱量と固有変形で整理した固有変形データベースを作成し、このデータベースから解析条件を決定する。本検討では、入熱パラメータは $Q/h^2=19.5$ で一定として解析を実施した。このときの固有変形 δ_x^* , δ_y^* , θ_x^* , θ_y^* を Table 2 に示す。





Fig. 3 Analysis model

Table 2 Inherent strain used in analysis


δ_x^* [mm]	-1.89E-01
δ_y^* [mm]	-2.89E-01
θ_x^* [rad]	-1.29E-03
θ_y^* [rad]	1.08E-02

3. 2 微小変形解析による検討

本節では、固有ひずみを用いた FEM 解析において、変位 - ひずみ関係を線形と仮定し、微小変形解析を行う。前章式(1)を用いて、Fig. 4 に示す碗型、鞍型、捩れ型を目的形状として学習させた AI に、それぞれの目的形状を作成するための加熱方案を予測させる。学習させた AI によって得られたそれぞれの目的形状作成のための加熱方案を Fig. 5 に、AI による加熱方案を用いて解析を行った結果を Fig. 6 に示す。Fig. 5 から碗型作成時の加熱方案の特徴として、表面を縦横に加熱し、中央をくぼませるよう加熱していること、主に角変形を用いて満遍なく加熱していることが分かった。また、鞍型作成時の加熱方案の特徴として、持ち上げたい辺に対し平行に加熱すること、捩れ型作成時の加熱方案の特徴として、持ち上げたい角の対角線に対して平行に加熱していることが分かった。両者とも、角変形および縦曲がりを利用して目的形状を形成していることが分かる。目的形状を作成するための加熱本数は、碗型、鞍型、捩れ型それぞれ 9 本、9 本、13 本であった。また、Fig. 7 に直線 A-A' と B-B' 上の面外方向変位を示す。これらの結果から、提案した AI 線状加熱システムを用いることで、十分に目的形状に近づく加熱方案を作成可能であることを示した。




(a) Bowl shape



(a) Bowl shape

(b) Saddle shape



(a) Bowl shape

(b) Saddle shape






Fig. 4 Target shape

Fig. 5 Heating plan by AI

Fig. 6 Obtained shapes



(a) On A-A' line



(b) On B-B' line

Fig. 7 Displacement in z direction

3. 3 大変形解析による検討

本節では、板厚を 8mm と仮定し、大変形解析を行う。変形量がそれぞれの加熱線による変形量の足し合わせで表される微小変形解析に対して、大変形解析では加熱線の組合せおよび加熱順序が重要となる。

大変形解析において、ある加熱線による変形量はこれまでの変形過程の影響を受ける。一方で、強化学習はマルコフ過程に基づいている。マルコフ過程とは、未来の挙動は現在の値によって決定し、過去の挙動と無関係であるという性質を持つ確率過程である。したがって、加熱線の組み合わせを考慮するにはこれまでの変形過程を含めた状態を定義する必要がある。しかしながら、変位分布の履歴を学習させると、加熱本数が増えるほどネットワークを大きくする必要があるため、問題が煩雑化する。そこで、これまでの加熱線を表面裏面でそれぞれ重ね合わせたものを、加熱履歴として学習させる方法を採用する。すなわち、状態を現在の目的形状との差と表面裏面それぞれの加熱履歴として、CNN の入力サイズを [40, 40, 3] に変更し学習を行う。

式(2)を用いて、加熱履歴を含めた状態と行動に対する価値推定値を AI に学習させた結果について示す。

Fig. 9 に、AI 線状加熱システムによる加熱方案を、Fig. 10 に加熱方案に従い解析した結果を示す。目的形状を作成するための加熱本数は、碗型、鞍型、捩れ型それぞれ 6 本、4 本、3 本であった。また、Fig. 11 に目的形状および解析結果について、直線 A-A' と B-B' 上の面外方向変位を示す。これらの結果から、十分に目的形状に近づく加熱方案を作成可能であることを示した。したがって、大変形解析結果、すなわち非線形現象も学習可能であると言える。

また、計算時間については、Fig. 9 の加熱方案を得るのにそれぞれ 16 時間、2 時間、6 時間の学習時間を要した。しかしながら、十分学習を行った AI による次の加熱線の予測にかかる時間は約 10 秒程度であり、実用的な計算時間と言える。




Fig. 9 Heating plan by AI




Fig. 10 Obtained shapes





Fig. 11 Displacement in z direction.

3. 4 AI 線状加熱システムの特徴

微小変形解析と大変形解析における、加熱方案のちがいについて検討する．ここでは、腕型形状の学習時に注目し議論する．Fig. 12 に、十分学習を行った AI 線状加熱システムによる加熱方案において、1 本目の加熱線を算出する際の CNN の出力、すなわち報酬の分布を示す．同図の(a)および(b)は、それぞれ、微小変形と大変形の倍の報酬の期待値の分布である．Fig. 12(a)より、微小変形解析では、加熱線 1 本の変形量が大きくなるため対角線上を加熱するような加熱線が高く評価されていることが分かる．一方で、同図(b)大変形解析においては格子状に加熱するような加熱線が高く評価されていることが分かる．

続いて、大変形解析における学習過程について検討する．Fig. 13(a),(b),(c)にそれぞれ、200 ケース、280 ケース、460 ケース学習した AI 線状加熱システムに、それぞれの時点で最も目的形状に近づくよう予測させた加熱方案を、Fig. 14 にその加熱方案を用いて解析を行った結果を示す．これらの結果から学習が進むにつれ加熱線配置が均整化されたことが分かる．また、Fig. 15 に 200 ケース学習時、280 ケース学習時、460 ケース学習時の加熱本数と目的形状との差を示す．同図から、学習が進むにつれ、少ない加熱本数で最終的に目的形状に近づく加熱線を選択するようになったことが分かる．Fig. 16 に学習ケース数と、その時点で作成させた加熱方案により解析を行った際の、終端における目的形状との差および終端までに要した加熱本数の関係を示す．加熱本数に関しては、終端において目的形状に 75%以上近づいたもの、すなわち目的形状との差が 25%以下になったもののみをプロットした．今回の学習においては、これ以上学習を進めても 460 ケース学習時よりよい加熱方案を得ることはできなかった．Fig. 16 から、学習初期には十分目的形状に近づく加熱方案を得ることはできなかったが、140 ケース学習以降、徐々に目的形状



(a) Small deformation analysis

(b) Large deformation analysis

Fig. 12 Distribution of expected reward




Fig. 13 Change of heating plan with increase of learning case




Fig. 14 Change of Obtained shapes with increase of learning case




Fig. 15 Change of error history




Fig. 16 History of error and number of heating line

に近づく加熱方案を算出できるようになってくること、さらに学習が進むと必要な加熱本数が減ることが分かる。したがって、少ない加熱本数で最終的に目的形状に近づく加熱線を評価するという報酬の与え方に基づき、適切に学習が行われたと言える。

以上より、提案した AI 線状加熱システムによって基本形状である腕型・鞍型・捩れ型を再現するための加熱方案を作成可能であることを示した。本稿で示した手法を用いることで、任意形状に対して、一度学習をすることで、極めて短時間で加熱方案を作成可能なシステムが構築できたとと言える。

4. 結言

本研究では、線状加熱工程の自動化を目指し、熱と変形という非線形の現象を取り扱うことから、強化学習と FEM シミュレーションを組合せることによって AI 線状加熱システムを提案した。提案システムを線状加熱における基本形状形成時の加熱位置の選定に適用することで、提案システムの有用性について示した。また、強化学習を用いた AI の学習能力および学習方法について検討を行った。本研究において得られた知見を以下に示す。

- 1) 提案した AI 線状加熱システムを目的形状形成時の加熱位置の選定に適用した結果、十分 AI の学習を行うことによって、微小変形解析および大変形解析において、目的形状に近づくための加熱方案を作成可能であることを確認した。
- 2) 提案した AI 線状加熱システムを目的形状形成時の加熱位置の選定に適用した際、学習には数時間から数十時間要するものの、十分に学習を行った AI による加熱方案の作成にかかる時間は約 10 秒程度であった。このことから、施工現場における実用可能性を示した。
- 3) 最終形状を元に報酬を算出し、加熱履歴を学習時の入力に加えることで、AI 線状加熱システムに加熱線の組合せを学習させた。現在の目的形状との差と加熱履歴という、性質の異なる複数の入力に対して CNN の学習を行うことができることを示した。また、加熱線の組合せを考慮した報酬の設定と加熱履歴の学習によって、非線形現象（大変形解析結果）も学習可能であることを示した。

参考文献

- 1) Y. TANGO, T. ISHIYAMA and H. SUZUKI: "IHIMU- α " A Fully Automated Steel Plate Bending System for Shipbuilding, IHI Technical Report (2011), Vol.51, No.1, 24-29.
- 2) D. Silver, A. Huang, C. J. Maddison, A. Guez, L. Sifre, G. Driessche, J. Schrittwieser, I. Antonoglou, V. Panneershelvam, M. Lanctot, S. Dieleman, D. Grewe, J. Nham, N. Kalchbrenner, I. Sutskever, T. Lillicrap, M. Leach, K. Kavukcuoglu, T. Graepel and D. Hassabis: Mastering the game of Go with deep neural networks and tree search, Nature, Vol. 529 (2016), 484-489.
- 3) C. J. C. H. Watkins and Peter Dayan: Q-learning, Machine Learning, (1992), 279-292.
- 4) V. Mnih, K. Kavukcuoglu, D. Silver, A. Graves, I. Antonoglou, D. Wierstra and M. Riedmiller: Playing Atari with Deep Reinforcement Learning, NIPS Deep Learning Workshop 2013.
- 5) D. P. Kingma and J. L. Ba: Adam: A Method for Stochastic Optimization, ICLR 2015.
- 6) T. Schaul, J. Quan, I. Antonoglou and D. Silver: Prioritized Experience Replay, ICLR 2016
- 7) Michel Tokic: Adaptive ϵ -Greedy Exploration in Reinforcement Learning Based on Value Differences, KI'10 Proceedings of the 33rd annual German conference on Advances in artificial intelligence, 203-210.
- 8) M. Abadi, A. Agarwal, P. Barham, E. Brevdo, Z. Chen, C. Citro, G. S. Corrado, A. Davis, J. Dean, M. Devin, S. Ghemawat, I. Goodfellow, A. Harp, G. Irving, M. Isard, Y. Jia, R. Jozefowicz, L. Kaiser, M. Kudlur, J. Levenberg, D. Mane, R. Monga, S. Moore, D. Murray, C. Olah, M. Schuster, J. Shlens, B. Steiner, I. Sutskever, K. Talwar, P. Tucker, V. Vanhoucke, V. Vasudevan, F. Viegas, O. Vinyals, P. Warden, M. Wattenberg, M. Wicke, Y. Yu, and X. Zheng: TensorFlow: Large-Scale Machine Learning on Heterogeneous Distributed Systems, Preliminary White Paper (2015).
- 9) Hidekazu Murakawa, Yu Luo and Yukio Ueda: Prediction of Welding Deformation and Residual Stress by Elastic FEM Based on Inherent Strain, Journal of the Society of Naval Architects of Japan, Vol. 180 (1996), 739-751
- 10) M. Shibahara, K. Ikushima, S. Itoh and K. Masaoka: Computational Method for Transient Welding Deformation and Stress for Large Scale Structure Based on Dynamic Explicit FEM, Quarterly Journal of The Japan Welding Society, 29-1(2011), 1-9.