

プレス機自らが考えて動く

機械学習を活用した知能化成形技術の構築

大阪産業技術研究所 和泉センター 加工成形研究部
主任研究員 四宮 徳章

(2020 年度 重点研究開発助成 課題研究 AF-2020001-A3)

キーワード：機械学習，鍛造，FEM 解析

1. 研究の目的と背景

プレス加工や鍛造をはじめとした製造業の現場では、近年、人材不足が問題になっている。特に、2002 年以降、全産業の就業者に対する製造業の就業者数の割合は低下を続け、2002 年には 19.0%であったものが 2022 年には 15.5%まで低下している。さらに製造業における若年就業者数は、この期間に 384 万人から 255 万人まで減少している¹⁾。

この人材不足を打破する方法の一つとして、塑性加工の分野においては人工知能 (Artificial Intelligence, 以降 AI) の活用が進められている。AI を活用することで、加工条件の最適化や不良発見に要する作業時間を大幅に短縮することができる。著者らは、サーボプレスなどのスライドモーションをコントロールできるプレス機を AI と組み合わせることで、知能的なスライドモーション制御を実現できると考えている。知能的なスライドモーションは、言わば匠の技に相当し、状況に応じて叩き方を変えるという熟練技術をプレス機に搭載することを想定している。

本研究では、(1)プレス機械を AI 対応に改造、(2)畳み込みニューラルネットワーク (Convolution Neural Network, 以降, CNN) を用いたインパクト成形の知能化、(3)強化学習を用いた熱間鍛造の最適化に取り組んだ。本稿では紙面の都合上、(2)および(3)について抜粋した結果のみ報告する。それぞれの詳細については、既発表論文^{2), 3)}を参照いただければ幸いである。

2. CNN を用いたインパクト成形の知能化²⁾

2.1 CNN について

Neural Network (以降, NNW) とは、図 1 に示すように信号の伝達により、入力に対する出力結果を求める数値モデルである⁴⁾。入力に対する出力の関係を事前に学習することで、未知の入力データから出力結果を予測することが特徴である。この予測のことを機械学習の分野では推論と呼び、本稿でもそのように記載する。

近年、画像認識においては、この NNW を発展させ、畳み込み演算を用いた CNN が推論精度の向上に大きな成果を上げている⁵⁾。一般的な NNW では、全結合層と呼ばれるすべての入力データを結合するネットワークで構成されていることに対して、CNN では、空間的に近い情

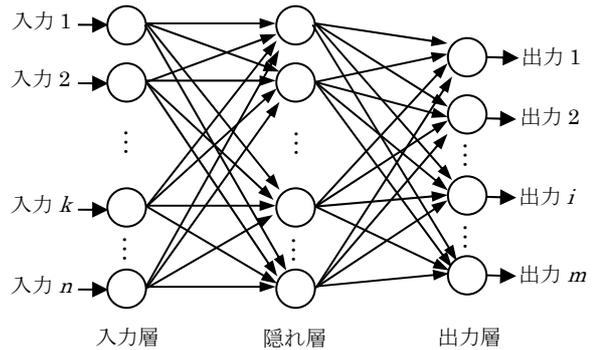


図 1 NNW の模式図

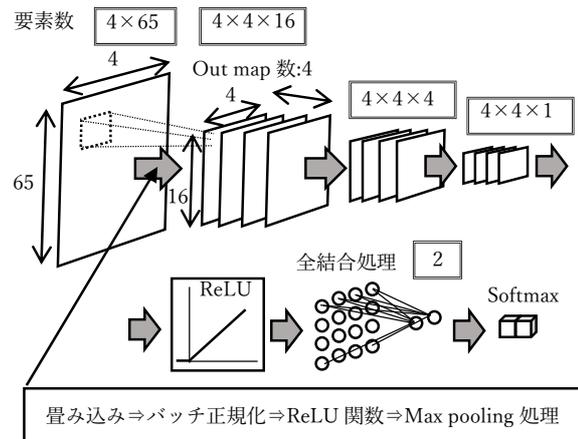


図 2 畳み込み演算を用いた NNW(CNN)の概要

報の関連性を考慮したネットワークで構成されている。この空間的な情報の関連性を、本稿では、時系列の情報の関連性に利用できると考え、塑性加工中の金型の弾性ひずみなど時系列データの認識に用いることを試みた。

本稿で用いた CNN を図 2 に示し、概要を説明する。まず、準備した 4×65 画素の画像 (本稿では、4 チャンネルのひずみの時系列データ (65 サンプル) を画素に並べたものとして扱った) に対して、4 枚の異なるフィルタを用いた畳み込み演算と、 1×4 画素ごとの特徴量を抽出する Max pooling 処理により、 $4 \times 4 \times 16$ へと変換する。同様の処理をさらに 2 回行い、最後に全結合層を用いることで 2 要素までデータ量を圧縮し、それぞれの数値の大きさと良品か不良品かを分類した。

2・2 実験方法

最適なスライドモーションを事前に見つけ、不良の発生が予測された際に、それを回避できるスライドモーションに切り替えるという知能化プロセスの準備として、不良率を低減できるプレス動作について検討した。

図3に、インパクト成形用金型の概観を示す。パンチの根元に汎用箔ひずみゲージを正面2点、背面2点の計4点貼付し、成形中のひずみ履歴を測定した。被加工材はA1050-H24を用い、せん断加工により所定の寸法に切り出し、バレルリングによりステアリン酸亜鉛を潤滑処理した。成形品側壁部の厚みは0.7 mmを設計値としており、断面積減少率は70%程度である。パンチストロークは7 mmに設定した。実験結果の評価については、外観検査として、割れ、しわの発生の有無や、側方から見て曲がりがないかを調べた。また、成形品の正面と背面に現れる被加工材の底面側の角部跡の高さをそれぞれ h_{front} 、 h_{back} とし、正面と背面の h の差、 $|h_{\text{front}} - h_{\text{back}}|$ を形状精度と関連のある Δh と定義して、その大小でも成形の良否を評価した。

FEM解析は、Simufact Forming 2021を用いて行った。被加工材は弾塑性体、パンチは弾性体、ダイスは剛体とした。材料データは、ソフトウェアに収録されているものを用いた。ダイスの凹部に被加工材を設置した様子を上方から見た模式図を図4に示す。成形不良の要因を調べるために、図に示すように、(a)中央に設置した場合、(b)中央から短辺と平行方向に0.1 mmおよび0.2 mmずらして設置した場合、(c)面内方向に0.5°傾けた場合の4条件について解析した。既報では、パンチの前進と後退を繰り返すパルスモーションによって成形精度を向上できる⁶⁾ことを報告した。本稿では、さらにパルス開始位置やパルス時のスライドの前進量であるパルス幅の大きさについて、FEM解析を用いて詳細に考察した内容について説明する。

2・3 FEM解析結果

実際の製品での成形不良は、長辺側の壁面厚さの偏りや、片側の長辺での破れがほとんどであった。そのことより、成形中にパンチが短辺と平行方向にずれることが成形不良を引き起こす要因と考えた。そこでまず、パンチのずれに及ぼす被加工材の設置位置の影響を調べた。図5に結果を示す。図より、金型中央から被加工材が大ききずれるほど、パンチのずれ量が大きくなることがわかる。一方で、金型に対して被加工材が回転した場合にはパンチのずれは小さいことがわかる。よって、被加工材が金型中央からずれた場合に発生するパンチのずれ量を小さくする方法としてパルスモーションを検討した。

図6に、被加工材を短辺と平行方向に0.2 mmずらして設置した場合の、成形中のパンチのずれに及ぼすパルス開始位置の影響を示す。なお、パルス幅の大きさは0.1 mmとした。パルス加工を行わない場合、ストロークが進むとパンチのずれ量が大きくなり、0.6 mmのストローク位置で0.23 mm程度とずれ量が大きくなった。しかし、パルス加工を行うことで、一度のパルスにより、パンチのずれ

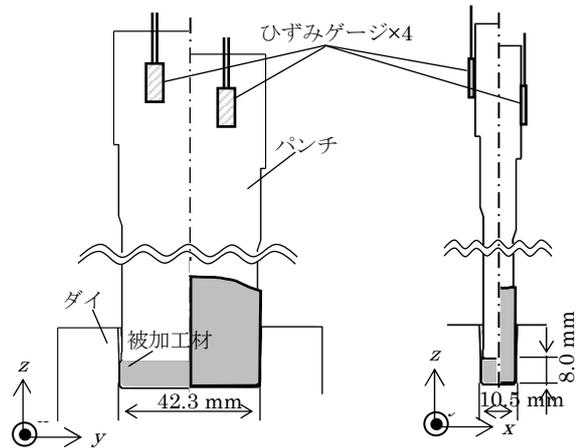


図3 インパクト成形用金型

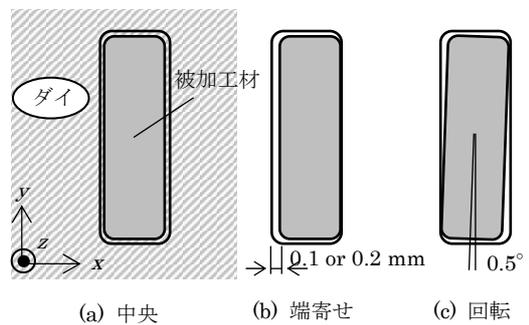


図4 被加工材の設置位置

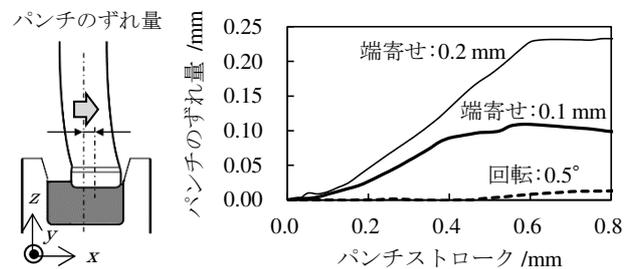


図5 パンチのずれ量に及ぼす被加工材の設置位置の影響

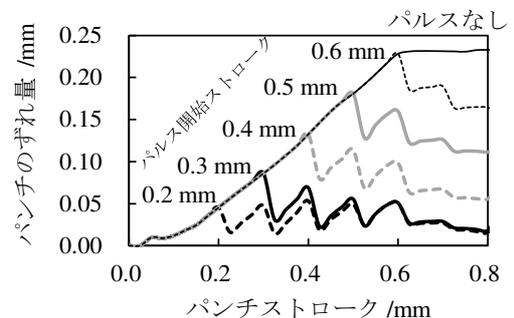


図6 パンチのずれ量に及ぼすパルス開始ストロークの影響

量を改善できることがわかる。パンチのずれはパンチの曲げ方向における弾性変形によって生じており、パルスを行うことでその弾性変形をリセットできたことが要因と思

われる。また図より、パルス開始位置が、0.2 mm あるいは 0.3 mm の場合にパンチのずれ量が小さくなることがわかる。また、パルス幅の大きさについて調べた結果、パルス幅を小さくするほど、パンチのずれ量は小さくなり、パルス幅を 0.05 mm とすることでパンチのずれ量を 0.01 mm 程度まで小さくできることがわかっている。

2・4 知能化実験結果

成形実験は、1,300 kN 油圧プレスを用いた。スライド速度は 5 mm/s とし、スライドモーションは、スライド速度一定のモーションと、FEM 解析で求めたパルス開始位置 0.3 mm、パルス幅 0.05 mm のパルスモーションとした。なお、パルス動作はストローク 1.0 mm で終了し、その後は速度一定のモーションとした。図 7 に成形実験の結果を示す。それぞれ 10 個の成形品のうち、パルス加工を行わない場合、良品は 2 個であったが、パルス加工を行うことで 8 個まで向上した。

次に、知能化の手順を以下に述べる。成形初期におけるパンチの弾性ひずみをデータロガーで取得し、推論を行うことで成形の良否を推論する。その推論結果に応じて所定の電圧をアナログ電圧出力器より出力する。電圧値は、成形不良になる推論結果であれば、プレス機がモーション変更（パルス加工に変更）を判断するトリガ電圧とし、成形良品になる推論結果であれば、トリガ電圧未満とすることで、モーション変更を行わず下死点までスライドを進行させる。

知能化プレス成形の検証結果を図 8 に示す。10 個の成形品では、割れ、しわ、大きな曲がりは確認されなかった。また、10 回の成形のうち、パルスの発動は 4 回あり、そのうち 1 個は Δh が 4.74 mm と大きいですが、それ以外は Δh が小さく良好な成形であった。なお、パルス未発動時の成形時間は、8 s に対して、パルス発動時の成形時間は 29 s である。10 回の成形において、すべてパルスを用いた成形とすると 290 s を要することに対して、知能化による選択的なパルス発動によって、合計 164 s の成形時間となった。知能化による選択的なパルス発動で、不良率を低減できるだけでなく、成形時間を大幅に短縮できた。

3. 強化学習を用いた熱間鍛造の最適化³⁾

3・1 強化学習について

強化学習は、機械学習の手法のひとつであり、変化する環境の中で、試行錯誤を通して最適な行動戦略を獲得してゆくための枠組みである⁷⁾。図 9 に強化学習の概要を示す。環境における状態を観測し、エージェントと呼ばれる行動を決める役割の部分が行動を選択する。適切な結果をもたらす行動には正の報酬 (Reward) が与えられ、不適切な結果をもたらす行動には罰として負の報酬が与えられることで、最終的に最も高い報酬が得られる行動の選択を目的に学習するものである。

3・2 実験方法

熱間鍛造では、被加工材の組成および鍛造温度や冷却速

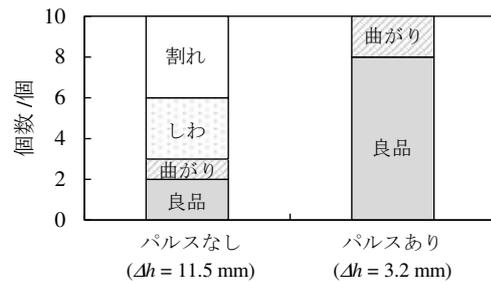


図 7 成形実験の結果

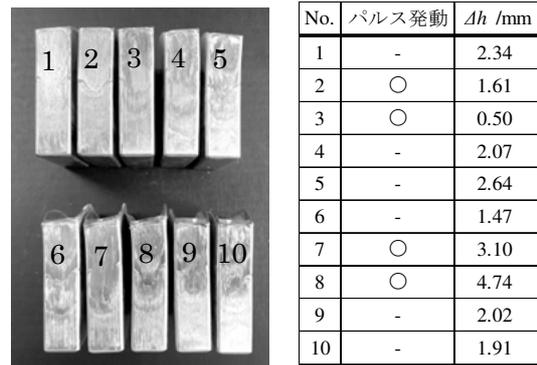


図 8 知能化プレスの成形結果

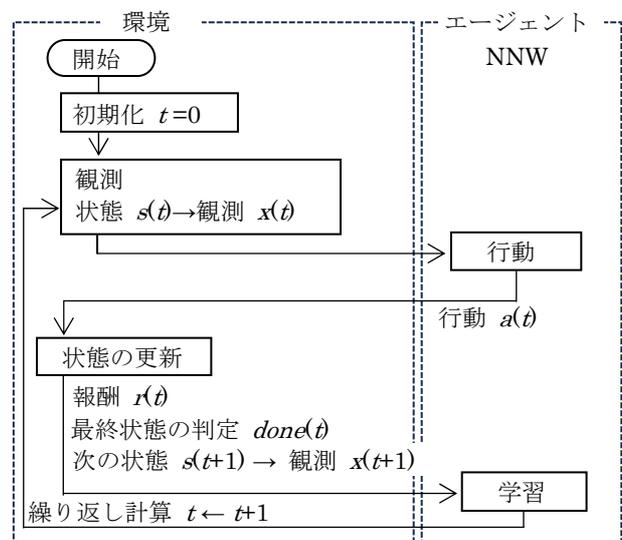


図 9 強化学習の概要

度によって成形品の強度が変化する。特に、機械式定着鉄筋⁸⁾では、熱間鍛造後の熱処理は行わないことが一般的であるため、それらの要因による強度の変化が大きい。成形品の強度安定と鍛造時間の短縮を目的に、強化学習を用いた熱間鍛造条件の最適化を行った。

棒状の被加工材を、機械式定着鉄筋を模擬した形状に熱間鍛造し、金型上の下死点保持で焼入れを行う第一工程と、成形品の強度を引張試験により求める第二工程について、実験および FEM 解析を行った。熱間鍛造試験および引張試験の概観を図 10 に示す。鍛造の上型および下型には、

カートリッジヒータおよび熱電対を挿入し、それぞれ独立して温度を制御できるものとした。熱間鍛造では、被加工材の下型天面からの突き出し部の据込みにより頭部を成形した。また引張試験については、成形品の首下を保持できる治具を製作し、胴部をチャックすることで行った。被加工材はSD295異形棒鋼で、購入先・購入時期により組成の異なるA ($\beta=1.26$)、B ($\beta=1.46$)、C ($\beta=1.60$)の三種を準備した。なお、 β は組成から計算できる焼入れ性を示すパラメータ⁹⁾で、 β が大きいほど焼入れ性が良いものを示す。スライド速度 V_s は、4 mm/s および 5 mm/s、被加工材温度 T_{wp} は、1,050 °C、1,100 °C、1,150 °C、金型温度 T_{die} は 50 °C、100 °C、150 °C、200 °Cとし、下死点保持時間 t_{hold} は、0 s、1.0 s、2.5 s、5.0 s で変更できるものとした。

以上の条件で、上型の下死点保持の時間を調節することで、成形品の強度を向上させることを試みた。

3・3 実験およびシミュレーション結果

FEM 解析結果の一例を図 1 1 に示す。被加工材 B、スライド速度 5 mm/s、被加工材温度 1,000 °C、金型温度 100 °C で解析を行った結果である。下死点保持を行う場合、保持時間が長いほど、頭部のマルテンサイトが増加した。これは、温度の高い被加工材が、温度の低い金型内で急冷され、保持時間が長いほどマルテンサイトの変態割合が高くなる温度まで、冷却ができたためである。他の鍛造条件についても FEM 解析を行い、被加工材の組成や鍛造温度および金型温度により、マルテンサイトの変態割合が高くなる下死点保持時間は異なることを明らかにした。

すべての被加工材組成および鍛造条件で、実験と FEM 解析の結果を比較したものを図 1 2 に示す。縦軸には FEM 解析により求めた(a)強度、および、(b)鍛造荷重を正規化した値、横軸には実験により求めた強度および鍛造荷重を正規化した値を示した。さまざまな条件で比較した場合でも、概ね 20%程度の誤差で FEM 解析により実験結果を予測できている。これにより、FEM 解析結果を用いた代理モデルを構築し、強化学習時の学習用データとして用いることで学習を高速化した。

3・4 強化学習を用いた熱間鍛造条件の最適化

成形を、Step-1:成形前、Step-2:成形開始時、Step-3:下死点の3つのステップに分ける。各ステップの環境として、Step-1 では被加工材の組成および温度と金型温度、Step-2 および Step-3 では被加工材の温度および金型温度を観測する。行動については、Step-1 で待機時間 0 s、5 s、10 s、Step-2 で成形速度 4 mm/s、5 mm/s、Step-3 で下死点保持時間 0 s、1 s、2.5 s、5 s をいずれか選択する。Step-1 の待機時間とは、成形前にプレス動作を待機する時間を指し、金型上で 1 s 待機するごとに 10 °C、被加工材温度が低下するものとした。この温度低下は実験により求めたものである。

次に、報酬について説明する。Step-1 および Step-2 では負の報酬として待機時間や成形に要した時間に比例し

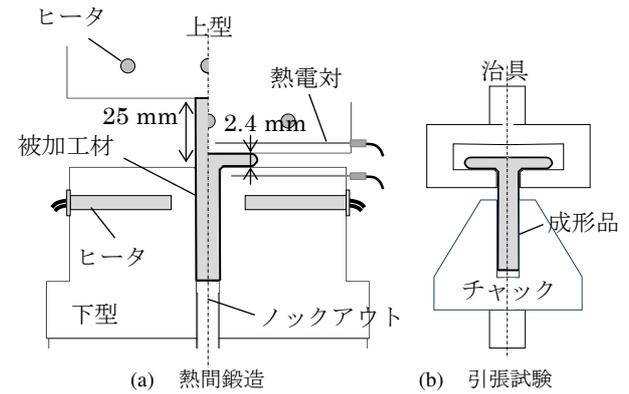


図 1 0 熱間鍛造と引張試験の概要

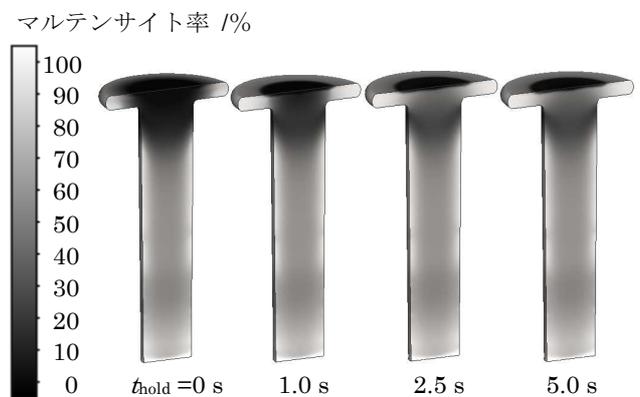


図 1 1 マルテンサイト率に及ぼす下死点保持時間の影響 (被加工材 B、 $V_s=5$ mm/s、 $T_{wp}=1000$ °C、 $T_{die}=100$ °C)

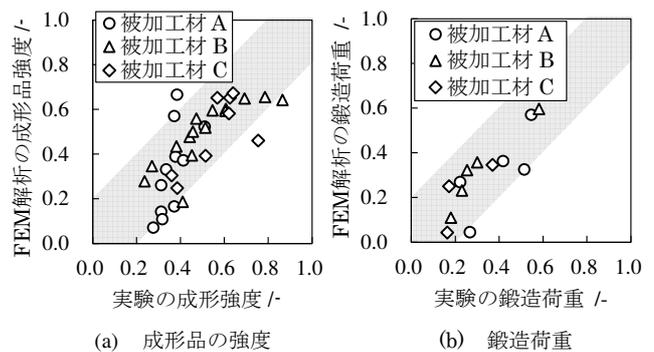


図 1 2 FEM 解析精度の検証

たもの、Step-3 では負の報酬として保持時間および成形荷重の大きさに比例したもの、および、正の報酬として成形品の強度に応じたものを与えた。負の報酬には係数(以降、罰則係数)を乗ずることでその影響の大きさを評価できるものにした。また、成形品の強度に応じた正の報酬としては、Reward-1: 強度の大きさに比例した報酬を与える方法と、Reward-2: 一定以上(60 kN 以上)の強度で定額の報酬を与える方法の二種類について検討を行った。

強化学習の結果評価として、学習済みの行動モデルの評

価を行った。行動の選択に及ぼす罰則係数の影響を調べた結果を図 1 3 に示す。なお、結果は、さまざまな組成、被加工材温度、金型温度における 10,000 回の評価結果の平均値を示している。Reward-1 および Reward-2 とともに、罰則係数を大きくして負の報酬の影響を強調することで Step-1 での待機時間および Step-3 での下死点保持時間が短くなる行動の選択が増えることがわかる。なお、成形速度については、いずれの場合でも 5 mm/s を選択する結果になった。

図 1 4 に、成形品の強度や成形時間、不良率に及ぼす罰則係数の影響を示す。なお、不良率については、成形品の強度が 60 kN 未満になる場合で求めた。罰則係数を大きくすることで、成形品の強度は低下し、不良率が上昇するが、成形時間は短くなることがわかる。Reward-1 や Reward-2 において、罰則係数を 0.2 に設定すると、成形時間が短い上に、鍛造荷重および不良率の低い結果が得られた。

以上より、強化学習のプログラムにおいて、報酬の定め方に主観としての罰則係数を設定することで、重要視するパラメータを考慮した行動の選択が可能になることが明らかになった。

図 1 5 に強化学習により知能化したスライドモーションを用いた熱間鍛造の実験結果を示す。鍛造条件としては、鍛造温度、金型温度、被加工材の組成をランダムに設定したものを用いた。知能化スライドモーションである Reward-1 および Reward-2 とともに、今回実験を行った鍛造条件では、鍛造前の待機時間は 0 s で、スライド速度は 5 mm/s の動作が採用されたため、違いの生じた下死点保持時間について結果を示している。また、下死点保持時間の違いだけでは、鍛造荷重に影響を及ぼさないため、成形品強度と下死点保持時間の結果のみ示している。下死点保持時間が 0 s の場合、成形品強度は 44.1 kN であることにに対して、下死点保持時間 2.5 s および Reward-1 では 46.1 kN と強度の高い成形品が得られた。また、Reward-2 においても成形品の強度は 45.4 kN と高い結果が得られた。一方、下死点保持時間を比較すると、Reward-1 では 2.2 s の結果が得られ、同等の強度を有する 2.5 s よりも 10% 以上短いことがわかる。また、Reward-2 では 1.1 s となり、2.5 s および Reward-1 と比較して下死点保持時間を半減できた。つまり、Reward-1 や Reward-2 では、成形品の強度の上昇と成形時間の短縮を両立でき、強度あるいは成形時間のどちらかを重視するかを、実装する知能化モデルの報酬の与え方で選択できた。

本研究では、FEM 解析結果から構築した代理モデルを用いて強化学習を行った。代理モデルは、他の事象や学習範囲外に対する汎用性は低く、改めて代理モデルを作成する必要があるが、精度の高い代理モデルを作成できれば、強化学習やその評価の高速化に効果的であった。また、強化学習では、学習の方向性に影響を及ぼす報酬は、ユーザ自身で決めることができる。報酬の決め方により、優先し

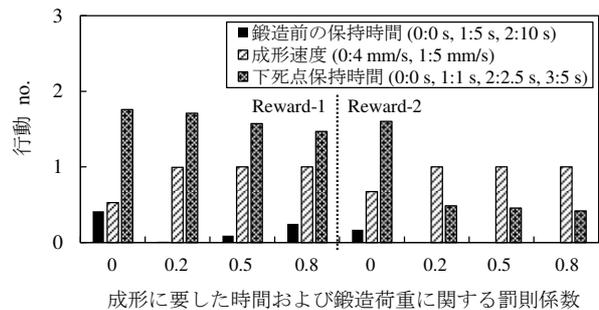


図 1 3 行動の選択に及ぼす罰則係数の影響

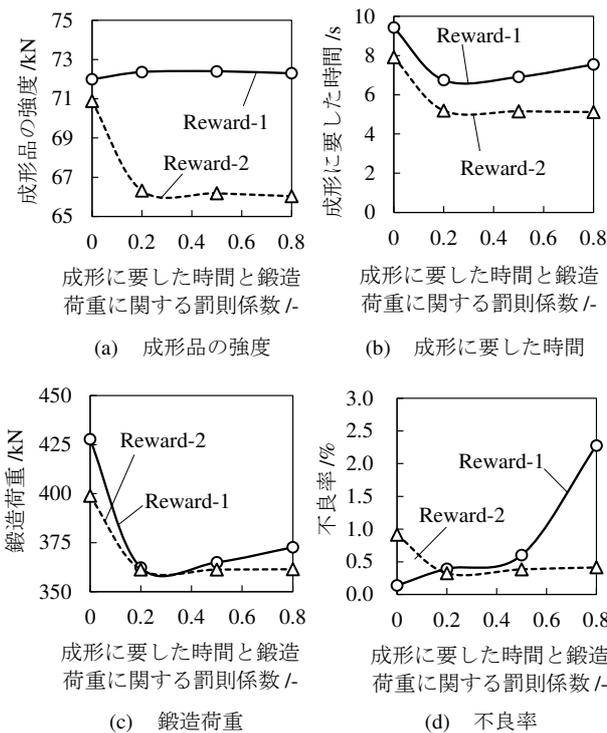


図 1 4 鍛造結果に及ぼす報酬の影響

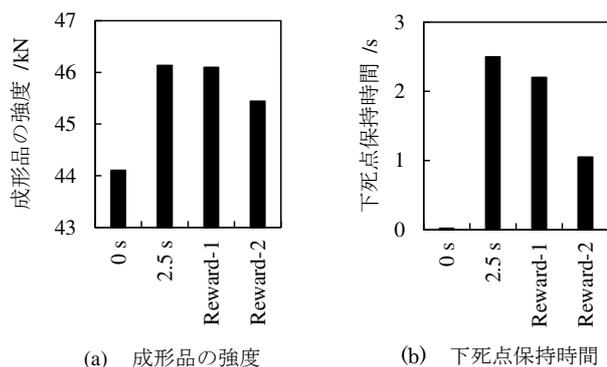


図 1 5 従来の熱間鍛造($t_{hold}=0$ s and 2.5 s) と知能化熱間鍛造(Reward-1, Reward-2)の比較

たい評価項目、例えば、成形品強度や成形時間、鍛造荷重などを主観的に選ぶことができ、ユーザの意図した知能化に効果的である。

4. 結言

本稿では、機械学習を利用して成形中にスライドモーションを変更する知能化に関するモデルケースとして、インパクト成形における不良率の低減、および、熱間鍛造の最適化について説明した。機械学習におけるネットワーク構造の検討や教師データの収集方法など、推論精度の向上のためにまだまだ改善の余地があると思われる。また、センサ技術の向上により塑性加工への機械学習の適用はますます拡大すると予想される。今後も研究を継続するとともに、活発な研究の推進を期待したい。

謝 辞

本研究は、公益財団法人天田財団 2020 年度重点研究開発助成 (AF-2020001-A3) を受けて実施されたものである。また、アサイ産業 (株) に当研究所所有のプレス機への AI 対応プログラムの導入および機器改造, (株) MORESCO に潤滑剤の提供をいただいた。ここに記して、謝意を表します。

参考文献

- 1) 経済産業省：ものづくり白書, (2023), 38-44.
- 2) 四宮徳章・坪井瑞記・喜多俊輔・安木誠一：塑性と加工, 64-748(2023), 87-92.
- 3) 四宮徳章・坪井瑞記・喜多俊輔・安木誠一：塑性と加工, 65-762(2024), 掲載決定.
- 4) 斎藤康毅：ゼロから作る Deep Learning-Python で学ぶディープラーニングの理論と実装-, (2016), 39-42, オライリー・ジャパン.
- 5) Sebastian, R. and Vahid, M. 著・(株)クイープ 訳：Python 機械学習プログラミング-達人データサイエンティストによる理論と実践, (2021), 447-448, インプレス.
- 6) 四宮徳章・白川信彦：塑性と加工, 56-654(2015), 570-574.
- 7) 牧野貴樹：生産研究, 66-3(2014), 305-308.
- 8) 迫田丈志, 石川裕次, 田才晃, 前田匡樹：コンクリート工学, 55-9(2017), 777-782.
- 9) 上野正勝, 伊藤亀太郎：鉄と鋼, 74-6(1988), 1073-1080.