

鍛造加工における CAE・AI を使った 技能継承に向けた DX の取組

片山 聡* 大川原 真** 木嶋 祐太* 櫻井 貴文* 須貝 裕之* 田辺 寛*
兼古 敦史*** 星野 勝亮*** 小林 龍雄*** 岸本 成人*** 原 知弘***

A Study on Digital Transformation for Skill Inheritance in Forging Process using CAE and AI

KATAYAMA Satoshi*, OKAWARA Makoto**, KIJIMA Yuuta*, SAKURAI Takafumi*,
SUGAI Hiroyuki*, TANABE Hiroshi*, KANEKO Atsushi***, HOSHINO Katsuaki***,
KOBAYASHI Tatsuo***, KISHIMOTO Shigeto*** and HARA Tomohiro***

抄 録

鍛造加工分野における技能継承を推進するため、CAE 技術による加工プロセスのデジタル化と機械学習を用いたデータ分析による暗黙知の形式知化に取り組んだ。本報告書では研究成果の一例として、(1)加工素材の材料パラメーター同定におけるデータ分析事例と、(2)AI 技術を用いたシミュレーション結果の予測事例について報告する。(1)では材料パラメーターと摩擦係数を同時に同定可能なサロゲートモデルを作成し、同定結果を用いたシミュレーションが実際の挙動とよく一致することを確認した。(2)ではシミュレーション結果を教師データとすることで、変形後の塑性ひずみ分布図を予測（出力）可能な機械学習モデルを作成することができた。

1. 緒 言

製造業においては、熟練技能者の経験に基づく勘やコツ（暗黙知）の継承が喫緊の課題となっている。鍛造加工をはじめとする塑性加工分野では、加工中に発生する音や振動をもとに加工条件の調整や予知保全が行われることが多く、その形式知化のため、近年では IoT（Internet of Things：モノのインターネット）技術を用いた加工情報の収集や、AI（Artificial Intelligence：人工知能）技術を用いた加工機の自律制御化に関する研究が行われている¹⁾²⁾。また、どの手順で加工するのが最適であるかといった工程設計技術についても自動化が進められている³⁾。

本研究では県内企業の技能伝承を推進することを目的に、作業工具の鍛造加工における暗黙知の形式知化（可視化）に取り組んだ。具体的

には、CAE (Computer Aided Engineering) 技術による加工情報のデジタル化と機械学習を用いたデータ分析により、鍛造加工結果に影響を及ぼす材料パラメーターや加工条件因子を特定した。また、AI 技術による最適加工条件の自動探索手法について調査・検証した。

本報告書では研究成果のうち、加工素材の材料パラメーター同定におけるデータ分析事例と、AI 技術を用いたシミュレーション結果の予測事例について報告する。

2. 材料パラメーター同定におけるデータ分析

2.1 概要

CAE 技術において、使用する材料モデルの正確さはシミュレーション精度に大きな影響を及ぼす要因のひとつとなっている。材料モデルの塑性挙動は、強度試験によって取得された応力-ひずみ曲線や、それを近似した関数によって定義される。強度試験には単軸引張試験や圧縮試験が用いられることが多いが、単軸引張試験

* 技術統括センター

** 県央技術支援センター


*** アネックスツール(株)

の適用範囲は一樣伸び限界（最大公称応力が生じる伸び）までであり⁴⁾、100%を超えるような大ひずみが生じる鍛造加工へ試験結果を適用するのは適切ではないと考えられる。一方、圧縮試験は実際の鍛造加工に近いひずみ域での試験が可能であるが、摩擦係数が大きい場合には高さ方向に樽型変形が生じ、単軸応力状態ではなくなくなるという問題がある⁵⁾。そのため、圧縮試験から応力-ひずみ曲線を得る場合には、摩擦係数の影響を考慮する必要がある。


そこで本研究では圧縮試験を対象に、逆解析による材料パラメーターと摩擦係数の同時同定を試みた。併せて、それぞれの値が圧縮試験結果に及ぼす影響について分析した。

2.2 圧縮試験

圧縮試験の様子を図 1 に示す。試験機には(株)島津製作所製万能材料試験機 UH-F500kNC を用いた。試験片は素材形状（丸棒）のまま使用し、端面は円筒面と同等の表面状態に仕上げた。試験片直径に対する高さの比は約 1.7、圧縮率（試験ストローク÷初期高さ）は 80%とした。また、試験片の端面は拘束せず、脱脂後、無潤滑で試験を実施した。試験環境は室温とした。圧縮試験結果の一例を図 2 に示す。



(1) 試験前



(2) 試験後

図 1 圧縮試験の様子

参考データとして、加工素材の引張試験結果を図 3 に示す。試験機には(株)島津製作所製万能材料試験機 AGX-300kNV を使用し、試験片は丸棒のまま（JIS Z 2241 14A 号試験片）とした。一樣伸び限界は 4%程度であり、引張試験を用いて大ひずみ域の材料データを取得することが困難であることがわかる。

2.3 サロゲートモデル

本研究における逆解析手法は、サロゲートモデルを用いた誤差最小化問題（最適化）とした。サロゲートモデルとは、シミュレーション条件とシミュレーション結果の関係性を学習し、それをもとに未知の条件に対する結果を「シミュレーションを実施せずに予測する」機械学習モデルである。シミュレーションを実施するよりも素早く結果が得られることから、多数の候補点が必要とする最適化との連携に適している。




図 2 圧縮試験結果




図 3 引張試験結果

サロゲートモデルの学習データ（シミュレーション結果）は SFTC 社製鍛造シミュレーションソフトウェア DEFORM-2D V13.1 (SP1) を用いて作成した。シミュレーションは 2 次元軸対称モデルで実施し、ソルバーパラメーターは弾塑性材料モデルに対するデフォルト値を用いた。材料モデルの塑性挙動は等方性硬化とし、変形抵抗は式(1)に示す Voce 則⁶⁾をもとに、多直線近似型で定義した。サロゲートモデルにおける入力変数は摩擦係数のほか、Voce 則パラメーター（降伏応力 Y 、飽和応力 S_∞ 、無次元定数 c ）とした。ただし、降伏応力が飽和応力を上回らないよう、降伏応力は降伏比（降伏応力÷飽和応力）により決定した。目的変数は、圧縮率－試験力曲線（勾配で重み付けして 16 点取得）および圧縮率後の端点移動量（図 4）とした。

$$\sigma = S_\infty - (S_\infty - Y) \exp(-c\varepsilon^p) \quad \cdots (1)$$

ここで、 σ ：真応力、 ε^p ：対数塑性ひずみ

学習データのサンプリング（実験計画法に基づく入力変数の組み合わせ）には Ansys 社製構造解析ソフトウェア Ansys Mechanical の応答曲面最適化機能 (Ansys DesignXplorer) を用いた。サンプリングアルゴリズムは最適充填設計（中心 L2）とし、学習データ数は 125 点とした。テ




図 4 端点移動量の評価位置

ストデータは学習データとは異なるランダムシードを用いて 25 点作成した。また、サロゲートモデルの作成アルゴリズムには遺伝的集合、最適化には多目的遺伝的アルゴリズムを用いた。なお、Ansys DesignXplorer の最適化では非劣解集合をもとに推奨される候補点を複数示すが、本研究においては最上位の候補点を同定値として採用した。

2.4 同定結果

作成したサロゲートモデルにおいて、各目的変数に対する平均絶対パーセント誤差は約 3% となった。同定値を用いて実施した圧縮試験シミュレーション結果を図 5 に示す。併せて、同定値から摩擦係数のみを大きくしてシミュレーションした結果と、引張試験結果から同定した材料特性値を用いてシミュレーションした結果（摩擦係数は同定値を使用）についても示す。図より、同定値を用いたシミュレーション結果は圧縮試験結果をよく再現していることがわかる。一方、摩擦係数を同定値よりも大きくした場合には、圧縮率が大きくなるにつれて誤差が増大しており、同定された摩擦係数の妥当性が確認できる。また、引張試験結果から同定された材料特性値を用いた場合には、試験力が実際の値よりも全体的に 20~30% 程度大きくなっており、低ひずみ域の応力－ひずみ曲線を鍛造加工シミュレーションへ適用することが困難であることを確認できる。






図 5 同定値によるシミュレーション結果

2.5 データ分析（寄与度分析）結果

通常、機械学習手法を用いて作成されたサロゲートモデルはブラックボックス化されているが、XAI（Explainable AI：説明可能な AI）技術を適用することで、モデル精度に影響を及ぼす入力変数や、入力変数値に対する目的変数の変動傾向を分析することが可能となる。本研究では Ansys DesignXplorer の寄与度分析機能を用いて、材料パラメーターや摩擦係数がサロゲートモデル（圧縮試験の予測結果）に対してどのような影響を及ぼしているか確認した。



(1) 試験力



(2) 端点移動量

図6 寄与度分析結果

表1 候補点の変動係数(単位:%)

圧縮率の最大値(%)	50	80
降伏比	4.33	4.40
飽和応力	0.57	0.75
無次元定数	3.95	6.79
摩擦係数	26.97	6.54

目的変数に対する入力変数の寄与度分析結果を図6に示す。試験力は飽和応力の影響が最も大きいが、圧縮率10%では降伏比や無次元定数の影響が、圧縮率80%では摩擦係数の影響が現れていることがわかる。また、端点移動量は摩擦係数に大きく依存していることがわかる。

加工力に対する摩擦係数の寄与度が圧縮率によって異なっていることから、同定に用いるデータ範囲の影響について確認した。同定に用いる圧縮率の最大値を50%および80%とした場合の同定結果（候補点上位20点の変動係数：標準偏差÷平均値）を表1に示す。データ範囲を50%までを対象とした同定結果は80%までを対象とした場合に比べ、特に摩擦係数の変動係数が大きくなっていることがわかる。これは、圧縮率50%では摩擦係数の影響が小さく、同定値が一意に定まらなかったためと考えられる。

以上のように、サロゲートモデルに対するデータ分析により、同定作業におけるデータ範囲設定の重要性を確認することができた。

3. AI技術を用いた画像予測モデルの作成

3.1 概要

上述のサロゲートモデル（以下、材料同定モデル）では、圧縮試験における加工力や端点移動量といった「数値」を予測したが、CAE技術は現象の可視化もその利点であることから、予測結果として応力分布図などの「シミュレーション画像」を出力（生成）するサロゲートモデル（以下、画像予測モデル）を作成可能であるか検証した。データセットは材料同定モデル作成時のものを用いた。

3.2 学習データ

画像予測モデルにおける予測対象は、圧縮率80%時の相当塑性ひずみ分布図とした。その一例を図7に示す。色階調は各シミュレーション結果の最小値～最大値に対して8階調とした。そのため、画像間で相当塑性ひずみの絶対値は統一されていない。学習では全条件の結果画像

150 枚を、学習データ 100 枚、検証データ 25 枚、テストデータ 25 枚に分割して使用した。

3.3 画像の生成方法

画像予測モデルの概念図を図 8 に示す。処理の流れは以下のとおりである。

【画像予測モデルにおける処理の流れ】

- ①4 次元の入力データを 2 層の多層パーセプトロンにより 128 次元の特徴量に変換する。
- ②128 次元の特徴量を各画素にコピーし、それに x 座標と y 座標の座標位置を加える。
- ③各画素に 130 次元の情報を持つデータを、4 層の畳み込みニューラルネットワークを用いて分布画像（各画素にひとつの値を持つデータ）に変換する。

学習条件を表 2 に示す。学習における損失関数には MSE（Mean Squared Error：平均二乗誤差）を用いた。また、ひずみ分布の色階調が少ないことによる境界部の大きな変化を避けるため、

TV（Total Variation：隣合う画素の差の総量）に重み比率 0.2 をかけて損失に加えた。画像予測モデルの構築には、オープンソースライブラリ PyTorch を利用した。画像の読込・保存、データ処理、ライブラリの組込みおよび評価結果出力プログラム作成には Python を用いた。

3.4 予測結果

作成された画像予測モデルにおいて、テストデータに対する MSE の平均値は 0.19、正解率（各画素の色階調一致率）の平均値は 82.1% となった。画像予測モデルによって作成された相当塑性ひずみ分布図を図 9 に示す。画像予測モデルはシミュレーション結果の特徴を概ね再現できているといえる。

今回の画像予測モデルでは比較的少ない学習データでシミュレーション結果を再現することができたが、これは図 6(2)にも示すように、端点移動量が摩擦係数に大きく依存していることが影響したものと推察される。このことを確認するため、摩擦係数のみを入力変数として画像



図 7 相当塑性ひずみ分布の例

表 2 学習条件

項目	値
エポック数	300
バッチサイズ	8
学習率	0.001
損失関数	MSE+0.2・TV




図 8 画像予測モデルの概念図



(1) 摩擦係数：小



(2) 摩擦係数：中



(3) 摩擦係数：大

図 9 相当塑性ひずみ分布

(上：シミュレーション結果，下：予測結果)

表 3 入力変数による予測精度の違い

入力変数	MSE	正解率
4 変数	0.19	82.1 %
摩擦係数のみ	0.19	81.8 %

予測モデルを再作成し，予測精度を確認した。結果を表 3 に示す。入力変数を摩擦係数のみとした場合においても予測精度が低下していないことから，上記の推察のように，ほぼ 1 変数に対する予測となっていたことがわかる。

4. 結 言

- (1) 圧縮試験結果より材料パラメーターと摩擦係数を同時に同定可能なサロゲートモデルを作成し，同定結果が実際の現象とよく一致することを確認した。
- (2) サロゲートモデルにおける入力変数の寄与度分析を実施し，摩擦係数の同定においては，高圧縮率時の試験結果を含める必要があることがわかった。
- (3) 圧縮試験における相当塑性ひずみ分布を予測するサロゲートモデルを作成し，予測結果がシミュレーション結果とよく一致することを確認した。

参考文献

- 1) 長洲慶典ほか，“加工センシングによるプレス金型異常検知に関する研究”，長野県工業技術総合センター研究報告，no.15 (2020)，pp.7-12.
- 2) 四宮徳章ほか，“強化学習を用いたスライドモーション制御による熱間鍛造の最適化”，塑性と加工，vol.65，no.762 (2024)，pp.100-107.
- 3) 小林康彦ほか，“ディスク部品を対象にした型打ち鍛造工程設計の自動化手法”，ぷらすとす，vol.7，no.77 (2024)，pp.272-276.
- 4) 片山聡ほか，“プレス成形シミュレーションの高精度化に向けた引張試験方法に関する研究”，工業技術研究報告書，no.54 (2024)，pp.55-62.
- 5) 吉田佳典，“シミュレーションのための材料試験-流動応力同定-”，軽金属，vol.68，no.5 (2018)，pp.266-273.
- 6) 桑原利彦，“初等塑性力学 (その 1)”，軽金属，vol.57，no.4 (2007)，pp.171-181.