

機械学習を用いた絞りスピニングにおける板厚制御

荒井 裕彦 (大東スピニング/産総研)

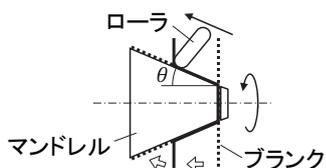
h.arai@daitohsp.co.jp, h.arai@aist.go.jp

1. はじめに

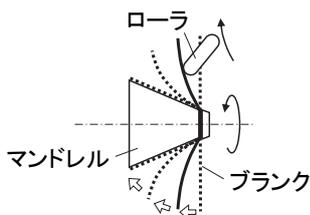
スピニング加工は回転する板材や管材をローラ工具で押し変形させ、所望の形状に成形する塑性加工法である^{1,2)}。プレス加工と比べて金型コストが低く試作や多種少量生産にも有利である。局所的な変形のため加工力が小さく製品寸法に比して装置の規模が低く抑えられる。ニアネットシェイプ加工であって材料の節約につながる。自動車部品、宇宙航空部品、化学産業、食品産業、空調機器、圧力容器、調理器具などに広く用いられている。

板材からの成形では目標形状のマンドレルにワークを押し付けて同じ形状を得る。板材のスピニングは金型側面に沿った単一のパスでローラを動かすしごきスピニング(**Fig.1 (a)**)と、複数のローラパスに沿ってワークを段階的に変形させる絞りスピニング(**Fig.1 (b)**)に大別される。本セミナーでは後者を取り上げる。

しごきスピニングの成形品の板厚 t は、ブランク板厚を t_0 、円錐半角を θ とすると一定値 $t_0 \sin \theta$ となる (sine 則)。それに対して絞りスピニングの成形品の板厚分布はローラパスに依存して変化し、薄肉化を抑制できるという利点を有する。一方、パスによってはワークにしわや破断が生じ成形に失敗する場合がある。目標の板厚分布を得る一般的なローラパスの設計法は確立していない。生産現場ではジョイスティックにより作業者が手動でローラを制御する教示再生式のスピニングマシンが用いられ、作業者の経験と試行錯誤によりローラパスを作成する場合が多い。熟練作業による手動のローラパスを記録し、ローラパス設計の経験的なルールを抽出する研究も行われている³⁾。



(a) しごきスピニング



(b) 絞りスピニング

Fig.1 板材のスピニング加工

絞りスピニングに関する従来研究としては、有限要素法(FEM)による成形シミュレーションにより、ローラ下の応力や歪みなどの変形メカニズムや、加工条件が成形品に及ぼす影響の解明が試みられてきた⁴⁻⁷⁾。加工パスの形状としてインボリュート曲線⁸⁾、楕円弧の一部⁹⁾、2次ベジエ曲線¹⁰⁾などが用いられ、加工パラメータと板厚の関係や、しわや破断の発生が研究されている。また絞りスピニングのプロセス全体を対象として、加工パラメータの加工結果への影響の統計的解析が行われた¹¹⁾。さらにプロセス全体の計画方法として、事例ベース推論とファジィモデルを用いて欠陥発生を回避する統計的手法が提案されている¹²⁾。また近年スピニング加工においても機械学習の応用が見られ、フローフォーミングにおける表面損傷の予測¹³⁾やボールスピニングにおける形状予測¹⁴⁾に人工ニューラルネットワーク(ANN)が用いられた。

本セミナーでは、機械学習を用いた絞りスピニングによる板厚の制御方法を紹介する^{15,16)}。FEMなどに基づく従来の研究ではパスと板厚の関係について定性的な傾向を指摘するにとどまっていたが、本手法では円筒カップの複数の点の目標板厚を同時に実現できる。ローラパスをパスの往復回数、寸法、形状などの複数のパラメータで表現する。それらのパスパラメータと成形品の板厚分布の関係を ANN で学習し、板厚分布をパスパラメータの関数として表す加工プロセスの予測モデルを作成する。板厚分布に目標値を設定し、数値解法によりパスパラメータを逆算して、希望する板厚分布を実現するローラパスを求める。得られたパスパラメータを用いて実際に円筒カップの成形を行い、目標の要求仕様を満たす絞りスピニングの加工プロセスが実現できることを確かめる。

2. ローラパス生成システム¹⁵⁾

多サイクルの絞りスピニングによる円筒カップ形状の成形において、ローラパスを自動的に生成するシステムを構築する。加工プロセスには、マンドレルで決定される目標形状以外に、成形品の高さや板厚などの製品仕様が定められている。複数の要求事項が与えられた時、それらを同時に満足するローラパスを、数理的な手段を用いて直接的に求める。そのためには以下の4つのステップが必要である。

- ① スピニングにおける多サイクルのローラパスを複数のパスパラメータで表現する。パスパラメータとしては、パス回数、パス寸法、ローラフィード比や、パスの形状を表わす様々な数値などがある。これらをベクトル

$$\mathbf{p} = (p_1, p_2, \dots, p_n) \quad (1)$$

で表わす。

- ② 加工プロセスの結果を複数の特性値で表現する。成形品の特性値としては高さ、板厚、スプリングバック、表面粗さなどが考えられる。これらは製品に要求される設計仕様として与えられる。これらをベクトル

$$\mathbf{q} = (q_1, q_2, \dots, q_m) \quad (2)$$

で表わす。ただし $n \geq m$ とする。

- ③ パスパラメータ \mathbf{p} と特性値 \mathbf{q} の関係を多変数ベクトル関数で表現する。スピニングにおいて安定に加工可能な範囲では加工プロセスに再現性があり、同じパスに対する加工結果は等しいと認められる。確率的要素の入らない決定論的なプロセスなので、パスパラメータ \mathbf{p} を与えれば特性値 \mathbf{q} は一意に決まる。したがって、多変数ベクトル関数 \mathbf{f} を用いて加工プロセスを

$$\mathbf{q} = \mathbf{f}(\mathbf{p}) \quad (3)$$

と表わせる。関数 \mathbf{f} は実験や FEM によるシミュレーションなどから導出することができる。本手法では実験結果を ANN に学習させることにより関数 \mathbf{f} を推定する関数 $\hat{\mathbf{f}}$ を構築する。

- ④ 成形品の特性値に設計仕様で決められた目標値 \mathbf{q}_d を代入し、望ましい加工プロセスを方程式

$$\mathbf{q}_d = \hat{\mathbf{f}}(\mathbf{p}) \quad (4)$$

と表わす。プロセス方程式(4)を未知の \mathbf{p} に関して逆問題として解くことにより、成形品の設計仕様を満たすパスパラメータ \mathbf{p} が決まり、工具パスが得られる。関数 $\hat{\mathbf{f}}$ は一般に解析的には表わされないため、ここでは反復解法により数値的に式(4)の解を求める。

2.1 ローラパスのパラメータ表現

多サイクルの絞りスピニングでは、ローラがマンドレルとワーク外周の間を往復しながら、ワーク形状を平板のブランクから円筒形状まで徐々に変化させる。ローラが通過するすべての座標値を加工結果と関連付けることは不可能なので、加工開始から加工終了までの1セットのローラパスをいくつかのパラメータで表現する。パラメータから生成されるローラパスは、しわや破断などの欠陥なく成形可能なパスを含むだけでなく、成形可能な範囲内で十分多様な特性の成形品が成形できる自由度を持たなくてはならない。

ローラパスは成形品に沿う直線パスとマンドレルにワークが接しない曲線パスから構成される。曲線パスは成形品側面からワーク外周に向かう一方のパスとした。曲線パスの形状は、外周に近づくほど主軸に対する傾斜角が大きくなる下に凸の形状である。このタイプの曲線パスは、しわが発生しにくくワークを安定に変形できるため、生産現場や多くの研究で採用される。一つの曲線パスが終了するとローラはワークに触れずに曲線パスの始点に戻って次の直線パスに接続する。曲線パスは単位円弧を x 方向（軸方向）、 y 方向（半径方向）に伸縮した下に凸の楕円弧であり、以下の式で表される。

$$\begin{cases} x = x_1 + (x_2 - x_1) \frac{\sin((\theta_2 - \theta_1)s + \theta_1) - \sin \theta_1}{\sin \theta_2 - \sin \theta_1} \\ y = y_1 + (y_2 - y_1) \frac{\cos \theta_1 - \cos((\theta_2 - \theta_1)s + \theta_1)}{\cos \theta_1 - \cos \theta_2} \end{cases} \quad (5)$$

ここでは $\theta_1 = 10^\circ$, $\theta_2 = 70^\circ$ とした。 (x_1, y_1) は曲線パスの始点、 (x_2, y_2) は曲線パスの終点である。 s ($0 \leq s \leq 1$) はパスの進行比率を表わし、始点では $s = 0$ 、終点では $s = 1$ である (Fig.2)。

ローラパスを表わすパラメータは以下のように構成される。 n_p はパス往復回数である。座標系の原点は、ブランク面の x 座標 x_{p0} 、成形品側面の y 座標 y_{p0} をそれぞれゼロとおき、これを原点とする。各曲線パスの始点は成形品側面に沿って x 方向に一定間隔 Δx_p で前進する。曲線パスの始点と終点を結ぶ傾斜角 α は初期値 α_0 から一定角ずつ増加し、最終パスで $\alpha = \pi/2$ となって成形品側面に沿う。 k パス目の傾斜角 α は $\alpha = \alpha_0 + (\pi/2 - \alpha_0)(k - 1)/(n_p - 1)$ となる。原点からスタートした最初の直線パスが外周に向かう最初の曲線パスに切り替わる点を $(x_{p_start}, 0)$ とする。各曲線パスの終点は $(x_{p_start}, 0)$ を中心とし (x_{p_start}, y_{p_end}) と $(x_{p_end}, 0)$ を通る $1/4$ 楕円上にある。 x_{p_end} はローラパスの終了位置の x 座標である (Fig.3)。

ローラパスの形状と寸法を規定するこれらのパラメータのうちで n_p , x_{p_start} , x_{p_end} , y_{p_end} , Δx_p , α_0 の6つを可変パラメータとする。これにパスに沿った1回転当たりのローラフィード比 P_{feed} を加えて、合わせて7つを式(1)のパスパラメータ \mathbf{p} の要素とした。

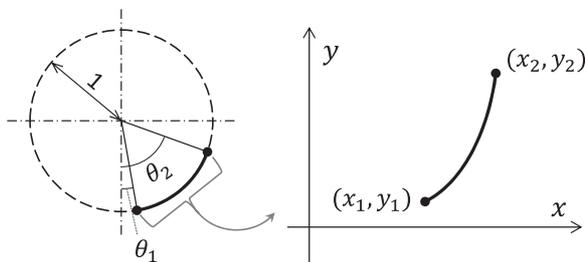


Fig.2 曲線パスの生成

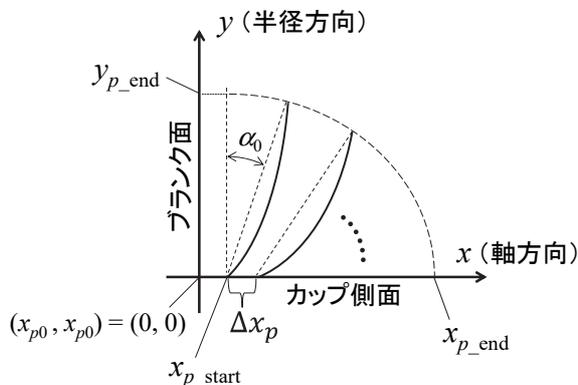


Fig.3 パスパラメータの構成

2.2 機械学習による加工プロセスの予測モデル

本システムでは実験結果を ANN に学習させることによりパスパラメータ p と特性値 q の関係 $q = f(p)$ を推定する関数 \hat{f} を構築する。一方、FEM シミュレーションによりパスパラメータ p から特性値 q を求めることも理論的には可能である。しかし次にプロセス方程式(4)を反復解法により解く段階で、関数 \hat{f} の計算を非常に多くの回数行う必要がある。そのため時間およびコストのかかる FEM の計算を反復解法に用いることは実用的ではない。学習終了後の ANN は計算が非常に早く、反復計算への使用に有利である。実験の代わりに FEM を用いるとしても、FEM の計算結果を予め ANN に学習させる方法が有益であろう。

ここでは ANN として任意の非線形関数を近似可能な多層パーセプトロン (MLP) を用いる。MLP の入力パスパラメータ p 、出力が特性値 q に相当する。MLP はそれぞれ複数のノードからなる入力層、隠れ層、出力層からなる。隠れ層と出力層の各ノードは前の層の各ノードから入力を受け取り、その重み付き和の非線形関数を出力する。この関数を活性化関数と呼ぶ。ここではシグモイド関数 $\zeta_a(x) = 1/e^{-ax}$ を用いた。

MLP の教師付き学習では、入力 p と出力 q の組合せからなる複数の訓練データに基づいてノード間の重み係数を調整する。すなわち訓練データの各サンプル入力 p を ANN に与えたときの出力が、 p に対応する訓練データのサンプル出力 q に収束するように重み調整の反復計算を行う。学習アルゴリズムとして MLP の教師付き学習に広く用いられるバックプロパゲーションを採用した。

2.3 反復計算によるプロセス方程式の数値解

最後に、設計仕様で定められた目標値 q_d を代入した方程式 (4) を数値的に解く。関数 $\hat{f}(p)$ の p に関するヤコビ行列を

$$J(p) = \frac{\partial q}{\partial p} = \frac{\partial \hat{f}(p)}{\partial p} \tag{6}$$

とする。行列 J の要素 J_{jk} は、 p の要素 p_k の微小変化を ϵ として、数値微分により

$$J_{jk} = \frac{\partial \hat{f}_j(p)}{\partial p_k} \cong \frac{\hat{f}_j(p_1, \dots, p_k + \epsilon, \dots, p_n) - \hat{f}_j(p_1, \dots, p_k - \epsilon, \dots, p_n)}{2\epsilon} \tag{7}$$

で近似計算できる。

パスパラメータ p の現在値 p_c により ANN から出力される値 $\hat{f}(p_c)$ と目標値 q_d の偏差 e を

$$e = \hat{f}(p_c) - q_d \tag{8}$$

とする。パスパラメータ p の修正則として計算が簡単な最急降下法を用い、転置ヤコビ行列 J^T を用いてパスパラメータ p の修正ベクトル Δp を計算した。

$$\Delta p = -\alpha J^T e \quad (\alpha \text{は係数}) \tag{9}$$

転置ヤコビ行列 J^T を構成する列ベクトルは q の各要素の勾配が最大となる方向を示す。したがって Δp は偏差 e の各要素を最もゼロに近づける方向の p の変化を各要素の値で重み付けして合成したベクトルになる。この Δp を用いてパスパラメータの現在値を

$$p_c \rightarrow p_c + \Delta p \tag{10}$$

と更新する。

(6)~(10)の計算を $q_d \cong \hat{f}(p)$ となるまで繰り返すことにより、目標値 q_d を実現すると推定されるパラメータ p が求められる。Fig.4 に上記アルゴリズムのフローチャートを示す。 p の要素が n 個の場合、反復ごとに $2n + 1$ 回の関数 $\hat{f}(p)$ の計算が必要であり、ANN の計算の高速性が役に立つ。

この方法で、理論的には最大でパスパラメータの個数と同じ個数の特性値を同時に目標値に一致させることができる。特性値の個数がパスパラメータの個数より少ない場合、パスパラメータは冗長となり、特性値を満たすパスパラメータの組合せは無数に存在する。提案するアルゴリズムはそのうちの一つの解に収束する。

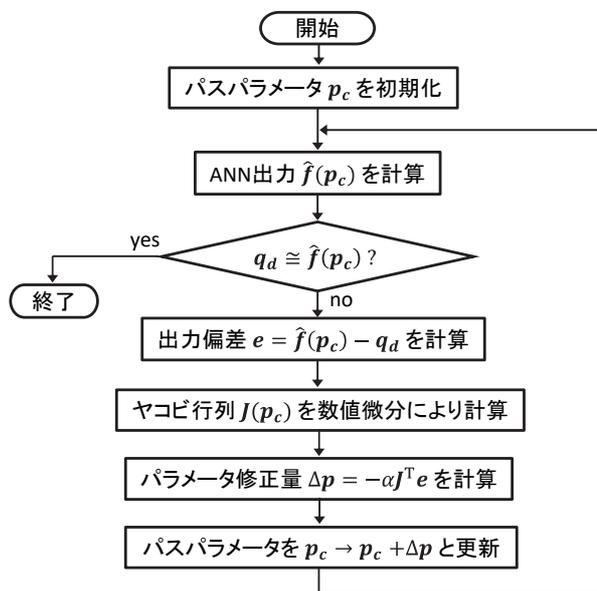


Fig.4 パスパラメータの数値解法

3. 実験

ブランクは直径 150mm、板厚 1.49mm のアルミニウム (A1050-O) 円板とする。中央に直径 20mm の固定用の穴が開けてある。直径 85mm、高さ 90mm の円柱形状のマンドレル (S45C 焼入) を用いた。ローラは工具鋼 (SKD11 焼入) で、直径 70mm、丸み R8mm である。マンドレル軸に対して 45°傾斜したローラホルダにローラを装着する。加工機として定格推力 1kN のリニアモータ駆動スピニング加工機¹⁷⁾を用いた。マンドレルの回転速度は 180rpm である。Fig.5 に実験装置を示す。

成形品の特性値 q として、側面の板厚、高さ h 、余剰パス長 r_p を取り上げた。板厚は底面からの高さ 25%、50%、75% の 3 か所の板厚 $t_{25\%}$ 、 $t_{50\%}$ 、 $t_{75\%}$ である。高さはハイトゲージ、板厚はマイクロメータで測定した。また余剰パス長 r_p は最後の直線パスにおいてローラが成形品の後端を通り過ぎる距離を意味し、次式で定義される。

$$r_p = x_{p_end} - (h + R_{round}) \tag{11}$$

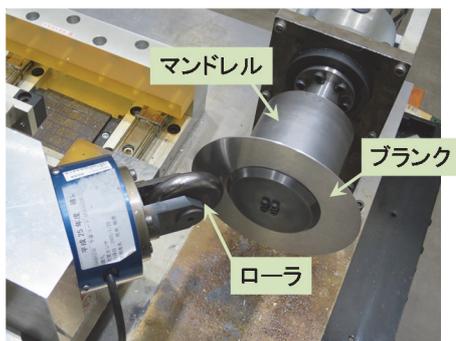


Fig.5 実験装置

ただし R_{round} はローラの丸み半径である。数値制御による絞りスピニングにおいて、各パスの終端位置は必ずしもワークの後端とは一致しない。 r_p が正の大きな値でパスがワーク後端を大きく通り過ぎる場合、成形に寄与しない無駄な時間が増加する。一方、 r_p が負でパスがワークの後端に達しない場合、ワーク外周にフランジが形成され、薄肉化や破断が発生する恐れがある。したがって r_p は0付近となることが望ましい。

ANN および数値解法はC言語でプログラムした。ANNの入力層のノードは7個である。隠れ層は1層で7個のノードからなる。5個の出力に対してそれぞれ独立のANNを構築した。バックプロパゲーション

法によるANN学習の反復回数は5000回に固定した。またANNによる推定性能を高めるため、ブーティング法によるアンサンブル学習を採用し、並行して学習した10個のANNの出力を合成して推定値を計算した。

3.1 ANNによる特性値の推定

はじめに、ANNにより板厚などの特性値が推定可能なことを検証した。予測モデルの関数 $\hat{f}(p)$ を構築するために、成形実験により取得したデータ群AをANNに学習させた。データ群Aは18組の入力(7個のパスパラメータ)と出力(5個の特性値)からなる。パスパラメータをパラメータ空間内で適度に配分するため、実験計画法のL18直交表を部分的に乱数化したパラメータ値を用いた。パラメータの範囲は $13 < n_p < 26$, $0 < x_{p_start} < 8$ [mm], $57.9 < x_{p_end} < 97.8$ [mm], $24 < y_{p_end} < 34$ [mm], $0 < \Delta x_p < (x_{p_end} - x_{p_start})/n_p$, $0 < \alpha_0 < 20$ [°], $0.8 < P_{feed} < 2.4$ [mm] とした。

また検証用のデータ群Bを成形実験により取得した。上記と同じ範囲内の一様乱数により18回分の加工のパスパラメータを計算し、破断が生じた1回を除く17組のデータ群Bにより予測モデルを検証した。Fig.6では、(a)高さ h と板厚(b) $t_{25\%}$, (c) $t_{50\%}$, (d) $t_{75\%}$ について、データ群BのパスパラメータをANNに入力して得られた推定値と成形実験における実測値を比較している。各グラフの横軸が推定値、縦軸が実測値である。

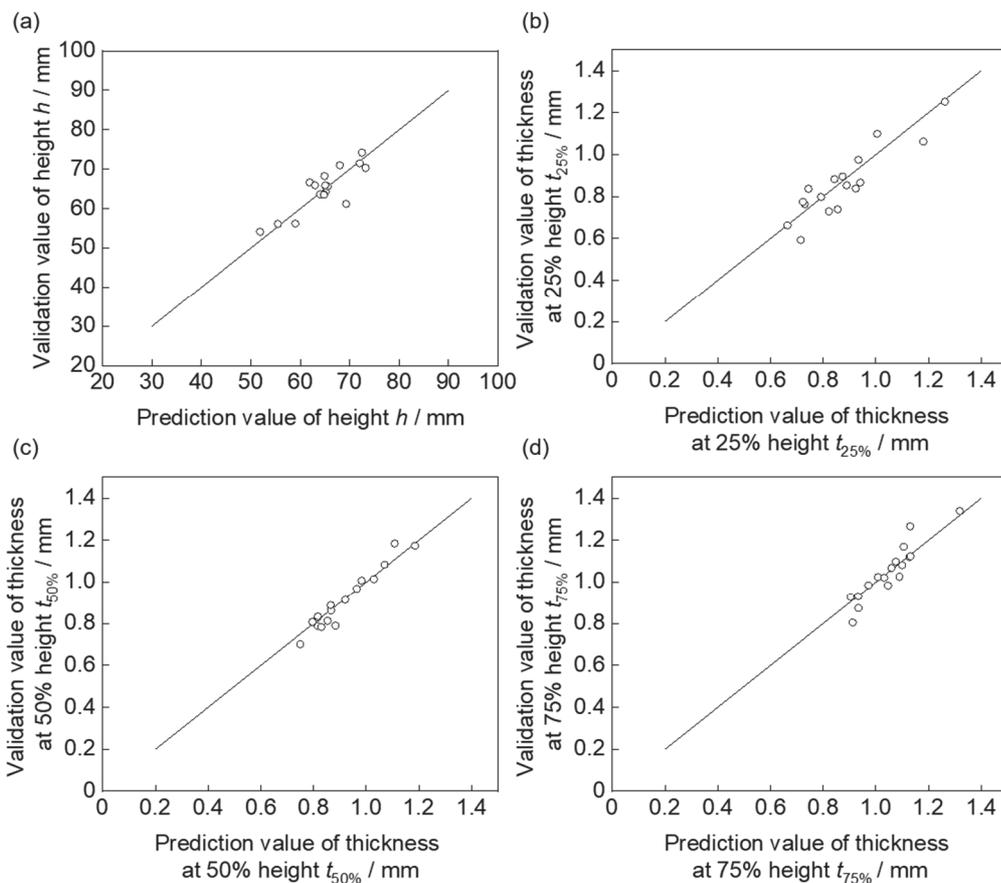


Fig.6 ANNによる推定値と実測値の比較

また推定値の実測値に対する二乗平均平方根誤差 (RMSE) および決定係数 (R^2) を計算した (Table 1). ANN による推定値は実測値とよく一致しており, パスパラメータと成形品の特性値の関係は ANN によって適切にモデル化されている.

Table 1 ANN 推定値の RMSE および R^2

| | 高さ | 板厚 | | |
|-------|------|------------|------------|------------|
| | | $t_{25\%}$ | $t_{50\%}$ | $t_{75\%}$ |
| RMSE | 2.93 | 0.07 | 0.04 | 0.05 |
| R^2 | 0.71 | 0.79 | 0.93 | 0.83 |

3.2 ローラパス生成システムによる特性値の制御

次に, 板厚などの特性値に目標値を設定し, 2.3 節の数値解法により目標値を実現するパスパラメータを求める. ANN の推定精度を向上させるために前節のデータ群 A, B を合わせた 35 組のデータを ANN に学習させた. 目標板厚は 3 か所の板厚が一定 ($t_{25\%} = t_{50\%} = t_{75\%}$) となるように与え, 0.6mm から 1.2mm まで 0.1mm おきに 7 通りの板厚とした. 円筒側面が一定の板厚で目標板厚となるカップの高さを計算し, これを目標高さとした. また式(11)の余剰パス長 r_p は目標値

を 0 とした. パスパラメータの初期値は学習データのパラメータを用いた. 式(6)~(10)の反復計算によりパスパラメータを求めたところ, 目標板厚 0.8~1.2mm の範囲で ANN 推定値が目標値に収束する 22 組のパスパラメータが得られた. これらのパスパラメータからローラパスを求め, 成形実験を行った. 同じ目標板厚に対しても異なる初期値からは異なるパスパラメータに収束するため, 同一の目標値に複数のパスパラメータが対応している.

Fig.7 は, (a)高さ h と板厚(b) $t_{25\%}$, (c) $t_{50\%}$, (d) $t_{75\%}$ に関して, 数値解法の目標値と成形実験における実測値を比較する. 各グラフの横軸が目標値, 縦軸が実測値である. 目標板厚 1.2mm で目標値からやや外れるケースが見られるが, おおむね目標値に近い板厚や高さとなっている. Table 2 は成形品の実測値の目標値に対する RMSE を示す. 最大 0.1mm 以内の RMSE で板厚制御が実現できている.

Table 2 成形品の実測値の目標値に対する RMSE

| | 高さ | 板厚 | | |
|------|------|------------|------------|------------|
| | | $t_{25\%}$ | $t_{50\%}$ | $t_{75\%}$ |
| RMSE | 1.87 | 0.086 | 0.013 | 0.094 |

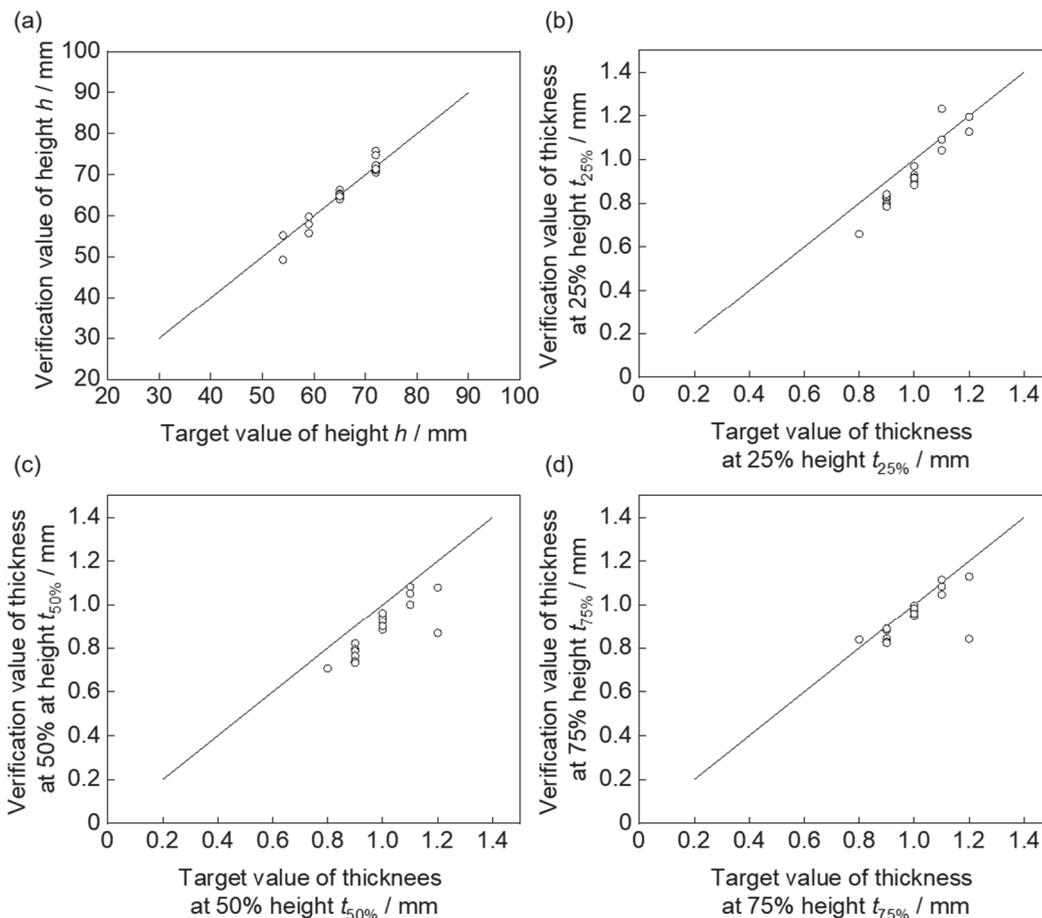


Fig.7 板厚・高さ制御における目標値と実測値の比較

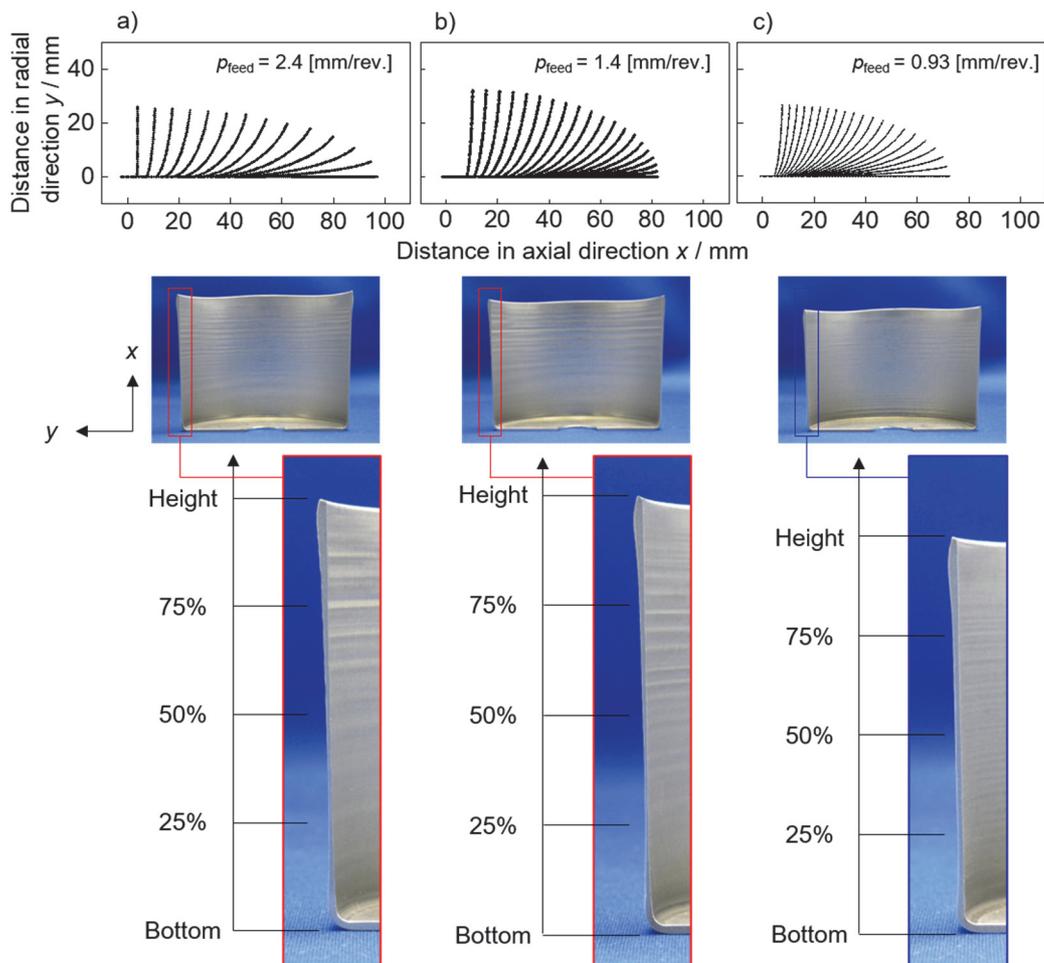


Fig.8 ローラパスと成形品断面の例 a)b)学習データ c)板厚制御の結果

Fig.8 にローラパスとそれによる成形品の断面の例を示す. a)b)は学習データ, c)は板厚制御の結果である. a)b)の断面では板厚 $t_{50\%}$ が $t_{25\%}$, $t_{75\%}$ よりも薄肉化し, 高さ方向の板厚の変動が顕著である. 一方 c)の断面では $t_{25\%}$, $t_{50\%}$, $t_{75\%}$ がほぼ等しくなるように成形されている.

4. ブランク・マンドレルの寸法変動への対応¹⁶⁾

ここまではブランクおよびマンドレルの寸法を1種類の組合せのみとした. しかし実際の現場では同じ円筒カップ形状でも様々な寸法のブランクとマンドレルの組合せで成形を行うことが必要となる. その際に, 寸法ごとに独立に ANN の学習を行うのではなく, 既に蓄積された別の寸法の学習データを有効に利用できれば効率的である. すなわち未学習のブランク・マンドレル寸法に対して, 異なる寸法のブランク・マンドレルによる学習結果に基づいて, 成形結果の予測や制御が可能となることが望ましい.

上記のような拡張を行うため, ANN に入力する式(1)のパラメータに対して, 加工ごとに可変となるパスパラメータのほかに固定的な加工条件に相当するパラメータを追加する. ブランクおよびマンドレルの寸法

はこうしたパラメータとして扱うことができる. 寸法パラメータ+パスパラメータの組合せで ANN の学習を行い, 未知の寸法パラメータ+パスパラメータを ANN に入力することで成形結果が予測できる.

ブランク直径 D , マンドレル直径 d として $(D, d) = (90, 50), (110, 50), (130, 85), (150, 85)$ の組合せについて8回ずつ成形実験を行い, 結果を ANN に学習させた. これらの組合せには含まれない $(D, d) = (120, 70), (140, 70)$ について ANN による推定値と実測値を比較した (Fig.9). グラフは板厚 $t_{50\%}$ のブランク板厚に対する比率を表わす. またプロットのうち一点について $t_{25\%}$, $t_{50\%}$, $t_{75\%}$ の比較を示した. いずれも推定値と実測値の一致は良好であり, 未学習の寸法でも成形結果の予測は可能である.

一方, 板厚や高さの制御においては, ブランク・マンドレルの寸法は一定値に固定し, 可変のパスパラメータのみを変動させて目標の特性値を実現するパラメータを求めることが必要である. そのためには式(7)のヤコビ行列をパスパラメータのみに関して特性値を偏微分した部分ヤコビ行列に置き換えればよい. 複数の寸法組合せの学習データで板厚を制御した結果を Fig.10 に示す. やや目標値から外れる場合も見られるが, おおむね目標値通りの板厚が実現されている.

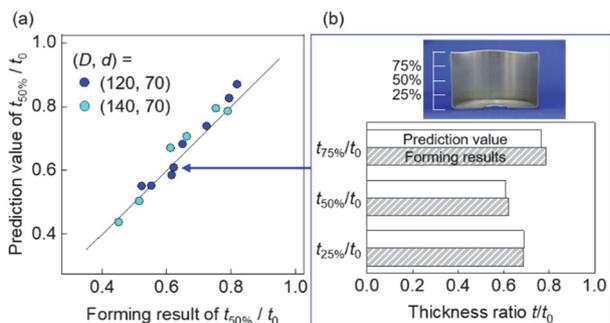


Fig.9 未学習の blanks・マンドレル寸法に対する板厚推定

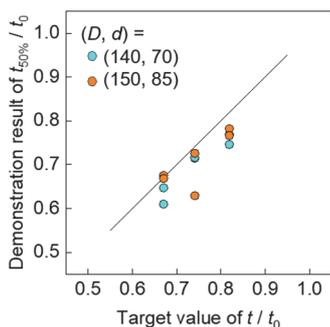


Fig.10 寸法混合の blanks・マンドレルによる学習データに基づく板厚制御

5. おわりに

機械学習を用いた絞りスピニングによる成形品の特
性値の制御方法を紹介した。円筒カップの多サイクル
絞りスピニングにおいて、ローラパスのパラメータと
加工結果の特性値データを ANN で学習し、複数の出
力目標値を実現するパスパラメータを数値解法により
求めるシステムを構築した。得られたパスパラメータ
で成形品の複数個所の目標板厚が同時に達成できるこ
とを実験的に検証した。

参考文献

- 1) C. C. Wong, T. A. Dean, J. Lin, A review of spinning, shear forming and flow forming processes, *Int. J. Mach. Tools Manuf.* 43 (2003) 1419–1435.
- 2) O. Music, J. M. Allwood, K. Kawai, A review of the mechanics of metal spinning, *J. Mater. Process. Technol.* 210 (2010) 3–23.
- 3) I. M. Russo, C. J. Cleaver, J. M. Allwood, Seven principles of tool path design in conventional metal spinning, *J. Mater. Process. Technol.* 294 (2021) 117131.
- 4) E. Quigley, J. Monaghan, The finite element modelling of conventional spinning using multi-domain models, *J. Mater. Process. Technol.* 124 (2002) 360–365.
- 5) M. Kleiner, R. Göbel, H. Kantz, C. Klimmek, W. Homberg, Combined methods for the prediction of dynamic instabilities in sheet metal spinning, *CIRP Annals - Manufacturing Technology* 51 (2002) 209–214.

Annals - Manufacturing Technology 51 (2002) 209–214.

- 6) C. H. Liu, The simulation of the multipass and die-less spinning process, *J. Mater. Process. Technol.* 192-193 (2007) 518–524.

- 7) S. Hamilton, H. Long, Analysis of conventional spinning process of a cylindrical part using finite element method, *Steel research international* 79 (2008) 632-639.

- 8) K. Kawai, M. Hayama, Roller pass programming in conventional spinning by NC spinning machine, *Advanced Technology of Plasticity*, 2 (1987) 711-718.

- 9) Y. Sugita, H. Arai, Formability in synchronous multipass spinning using simple pass set, *J. Mater. Process. Technol.* 217 (2015) 336–344.

- 10) J. A. Polyblank, J. M. Allwood, Parametric toolpath design in metal spinning. *CIRP Annals - Manufacturing Technology*, 64 (2015) 301-304.

- 11) K. Essa, P. Hartley, Optimization of conventional spinning process parameters by means of numerical simulation and statistical analysis, *Proceedings of the Institution of Mechanical Engineers, Part B: Journal of Engineering Manufacture* 224 (2010) 1691–1705.

- 12) R. Göbel, M. Kleiner, N. Henkenjohann, New approach for process planning and optimization in sheet metal spinning, *Advanced Materials Research* 6 (2005) 493–500.

- 13) N. P. Belfiore, F. Ianniello, D. Stocchi, F. Casadei, D. Bazzoni, A. Finzi, S. Carrara, J. R. González, J. M. Llanos, I. Heikkila, F. Peñalba, X. Gómez, A hybrid approach to the development of a multilayer neural network for wear and fatigue prediction in metal forming, *Tribology International* 40 (2007) 1705–1717.

- 14) S. Jiang, Z. Ren, K. Xue, C. Li, Application of BPANN for prediction of backward ball spinning of thin-walled tubular part with longitudinal inner ribs, *J. Mater. Process. Technol.* 196 (2008) 190–196.

- 15) S. Gondo, H. Arai, Effect and control of path parameters on thickness distribution of cylindrical cups formed via multi-pass conventional spinning, *Journal of Intelligent Manufacturing* 33 (2022) 617–635.

<https://doi.org/10.1007/s10845-021-01886-w>

- 16) S. Gondo, H. Arai, Data-driven metal spinning using neural network for obtaining desired dimensions of formed cup, *CIRP Annals* 71.1 (2022): 229-232.

<https://doi.org/10.1016/j.cirp.2022.04.044>

- 17) H. Arai, Force-controlled metal spinning machine using linear motors, *Proceedings of 2006 IEEE International Conference on Robotics and Automation (ICRA 2006)*, Orlando, Florida, (2006) 4031–4036.

本件配布先:産総研 → 経済産業記者会、経済産業省ペンクラブ、中小企業庁ペンクラブ、資源記者クラブ、
 文部科学記者会、科学記者会、筑波研究学園都市記者会

少数データから短時間で現場環境に応じた最適加工条件を決定 — 素形材産業における小規模製造現場のDXに貢献する作業支援汎用AIツール —

2022年1月17日

国立研究開発法人 産業技術総合研究所

■ ポイント ■

- ・ 一度の成形で狙い通りの製品寸法に成形できる AI へら絞り(スピニング)加工技術を開発
- ・ 少ない学習データでローラーの最適な動作経路を瞬時に決定し、試作時間を大幅に短縮
- ・ 加工条件の決定支援 AI ツールとして、素形材産業における小規模製造現場での活用を期待

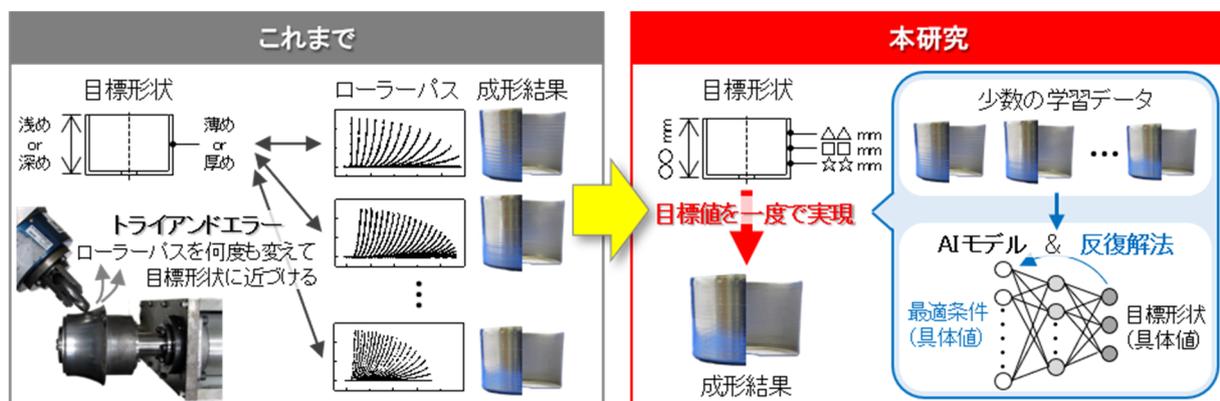
■ 概要 ■

国立研究開発法人 産業技術総合研究所(以下、「産総研」)製造技術研究部門 素形材加工研究グループ 権藤 詩織 研究員、荒井 裕彦 テクニカルスタッフは、一枚の金属板から立体形状に成形するへら絞り(以下、「スピニング」)加工において、AI を使ってローラーの最適な動作経路(以下、「ローラーパス」)を瞬時に決定する技術を開発した。短時間で容易に、立体形状の高さや板厚が狙い通りの寸法となるように成形できる。

スピニング加工は、回転する金属板の一部にローラーを押し当てて少しずつ変形させ、立体形状に成形する加工法である。プレス加工などの他の塑性加工法とは異なり、最終形状のみの金型さえあれば成形できるという特徴から、短時間で製品試作や多品種変量生産の場面で利用価値が高い。しかしながら、製品の高さや板厚などの寸法はローラーの動かし方ひとつで大きく変わってしまうため、狙い通りの寸法となるように加工するには、ローラーパスの決定に試行錯誤を重ねる必要があり、多大な時間と労力が必要であった。今回開発した技術では、少数のデータを使い、ローラーパスと寸法の関係をニューラルネットワークでモデル化し、さらに、反復解法と呼ばれる計算技法を用いて、具体的な目標仕様を実現する最適なローラーパスを瞬時に決定できる。これにより、一度の成形で狙い通りの寸法となるような加工が可能となる。少数のデータを AI に学習させ、目標仕様から最適加工条件を逆算して求める手法は即応性が高く、様々な素形材加工手法へも適用が期待できる。

なお、本成果の詳細は、2022年1月12日に [Journal of Intelligent Manufacturing](#) でオンライン公開された。

は【用語の説明】参照



少数の学習データによる AI を使った最適なローラー動作経路(ローラーパス)の決定

本件配布先:産総研 → 経済産業記者会、経済産業省ペンクラブ、中小企業庁ペンクラブ、資源記者クラブ、
 文部科学記者会、科学記者会、筑波研究学園都市記者会

■ 開発の社会的背景 ■

少子高齢化に伴う労働力不足は、全産業分野での社会課題である。素形材分野も例外ではなく、製造現場を支える中小企業において、技術・ノウハウの継承、人材育成が大きな課題となっている。そのような状況下、DX（デジタルトランスフォーメーション）への期待は大きく、ものづくりにおいてもスマートものづくりとして、デジタル化が進められている。しかしながら、素形材産業の各工程のうち生産に至る前の加工条件出しは、経験豊富な人材による、過去の経験と勘を頼りにした試行錯誤により行われ、デジタル化が積極的に進みにくい工程である。結果的に、加工の条件出しの工程がものづくり全体のDXのボトルネックになっているともいえる(図1)。

これまでも、加工条件と成形物の特性をそれぞれ入力、出力としたAIモデルを構築した事例はあるものの、出力の予測にとどまっているのが現状である。結果として、最適加工条件を決めるには幾通りもの入力をモデルに与え、出力値が目標値とほぼ同じかどうかで判断せざるを得ず、人手不足の環境下において、実用的ではなかった。また、対象とする出力がただひとつの場合が多く、複数の要求仕様を同時に満足できていなかった。さらに、これまでのAIモデルでは膨大な学習データが必要であり、小規模生産現場において、そのデータを事前に準備する工程は現実的ではない。多品種変量生産への対応がさらに要求されていく中、少ない学習データで、複数の要求仕様を同時に満たし、最適加工条件を瞬時に決定する技術が望まれてきた。



図1 ものづくり全体のDXに対する素形材産業でのボトルネックの状況

■ 研究の経緯 ■

産総研 製造技術研究部門では、少ない労働力で高付加価値を創製すること、社会・人々のニーズに臨機に応えた機能を提供することを目的に、IoT、AI を活用して得られたデータに基づき、能動的に設計、加工、評価を実施するものづくり技術の開発に取り組んできた。その一例として、スピニング加工技術を対象とした研究開発を行っている。

スピニング加工は回転する金属板にローラーを押し当てて逐次的に変形させる加工法である(図2)。これまで、製品の寸法はローラーパスや回転速度など多数の加工条件によって決まるという特徴を生かし、スピニング加工にロボット制御技術を活用することで、異形断面形状が成形できる新しいスピニング加工技術(3D スピニング)を開発した(産総研主な研究成果 2008年9月29日)。また近年では、ローラーの柔軟な動きを介した組織制御による機能創製を目的に、材料組織学の観点からスピニング加工中の変形メカニズムの解明を進めている。このように、スピニング加工と他技術・学問の学際的なコラボレーションにより、スピニング加工の高度化を図っ

本件配布先:産総研 → 経済産業記者会、経済産業省ペンクラブ、中小企業庁ペンクラブ、資源記者クラブ、
文部科学記者会、科学記者会、筑波研究学園都市記者会

てきた。しかしながら、具体的な目標寸法となるように加工を行うには、何度も条件を変えて試作を行い、条件の修正と寸法変化の傾向について感覚をつかむ必要があり、多大な労力と時間がかかっていた。これらを軽減するために、加工条件と製品寸法の間関係を捉えようとする研究がなされてきたが、多数の加工パラメータの影響を幅広く把握することができていなかった。このように、スピニング加工が抱える“加工条件出し時の試行錯誤への依存”は、依然として解決の難しい課題として残されてきた。

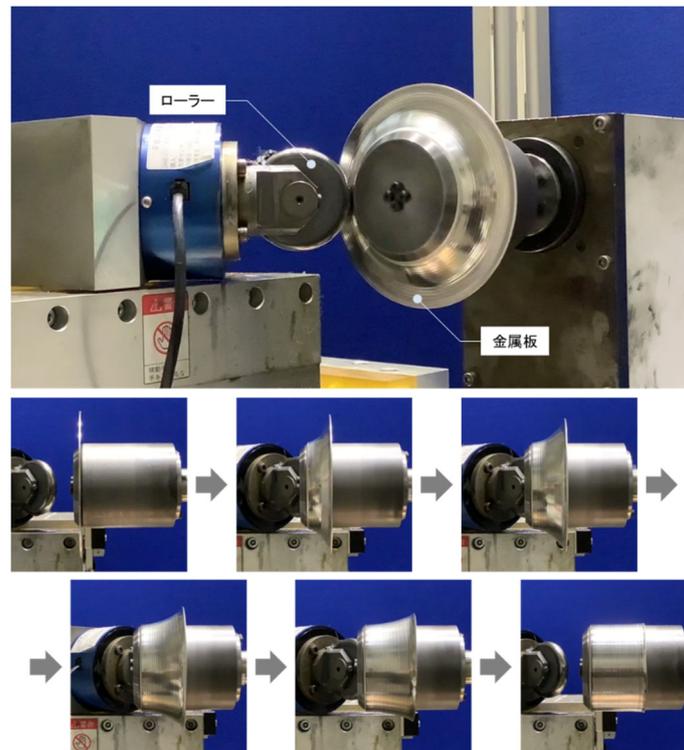


図2 スピニング加工の様子

今回、これを解決する手法として AI に着目した。ただし、既往の AI を活用した加工技術開発との差別化として、中小企業などの小規模生産現場を念頭に、作業者が簡単に取扱え、作業の支援となる AI ツールの開発に焦点をおいた。具体的には、作業者が操作するパラメータを入力とし、観測対象(本研究では製品の複数箇所板厚)を出力とするシンプルなモデルで入出力関係を表現することを前提とし、

- ・少数のデータでモデルを構築できるようにする
- ・最適化を行い、所望の板厚を実現する操作パラメータの具体値を出せるようにする

ことを技術目標とし、研究開発に取り組んだ。

■ 研究の内容 ■

本研究では、35通りの条件下で金属板をカップ状に成形し、これら少数のデータを使って、加工中のローラーパスを入力層、実際に加工したカップの高さと高さ方向に3点の板厚を出力層とするニューラルネットワークモデルを構築した。このモデルから、反復解法と呼ばれる計算技法を用いて、目標とするカップの高さと板厚分布となる最適なローラーパスを求めた(図3)。モデルの構築に使ったデータのほとんどは高さ方向に板厚が一定ではなかったが、反復解法で求められたローラーパスで実際に加工すると、誤差 0.1 mm 以内で高さ方向の板厚

本件配布先:産総研 → 経済産業記者会、経済産業省ペンクラブ、中小企業庁ペンクラブ、資源記者クラブ、
 文部科学記者会、科学記者会、筑波研究学園都市記者会

分布が 1.0 mm 一定となるように成形できた(図 4)。このように、複数の出力を同時に実現する最適な加工条件を瞬時に決定できる技術を開発し、一度の加工で狙い通りの製品寸法となるような成形を可能とした。

本技術は、膨大なデータを必要とせず少数のデータを使ってモデルを構築し、構築したモデルに最適化を施して、所望の板厚を実現する操作パラメータの具体値を容易に算出する。“製造現場の DX”は一般に、加工技術と AI の両方について専門知識を有する人材の確保・育成をしなくてはならない、必要な機材の初期投資が高いなどの印象が持たれ、製造現場は DX の導入をためらう傾向にある。これに対し、本技術は手軽に低コストで製造現場、特に加工条件出し工程の DX を試みたいと考えている企業にとって、導入しやすく、その後の運用も含め取り扱いやすい、汎用性の高い作業支援 AI ツールとなる。

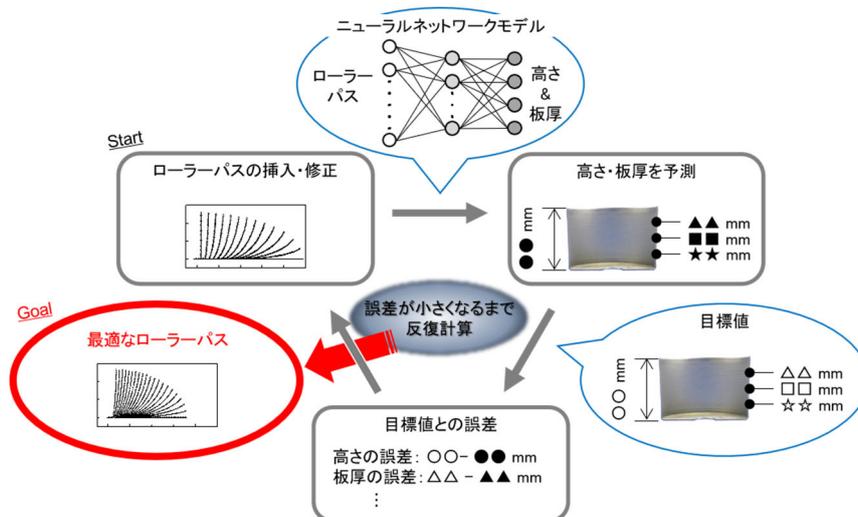
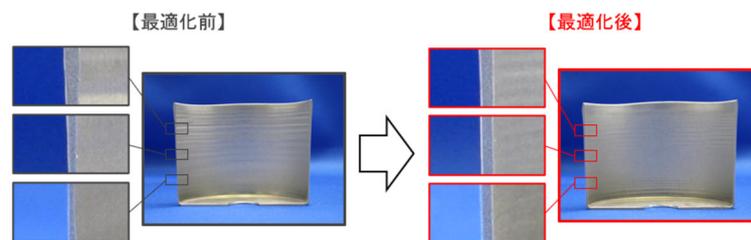


図 3 本手法における最適ローラーパスが求まるまでの流れ



板厚不均一サンプルを学習データとして使って構築したモデルから、板厚一定サンプルを実現!

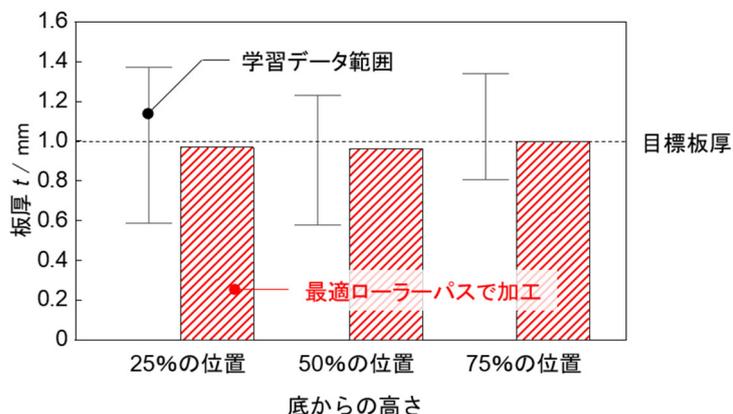


図 4 決定した最適ローラーパスによる板厚一定の実現

本件配布先:産総研 → 経済産業記者会、経済産業省ペンクラブ、中小企業庁ペンクラブ、資源記者クラブ、
文部科学記者会、科学記者会、筑波研究学園都市記者会

■ 今後の予定 ■

スピニング加工において取り扱う素材や金型の寸法、材質を拡張しながら、目標形状やローラーパスの複雑化に対応した、柔軟なモデルの開発を引き続き行う。同時に製造現場での実装を試み、より製造現場に寄り添うモデル開発を行う。また、本成果は、スピニング加工のみならずその他の素形材加工技術にも原理的に応用可能である。産学官の連携により本成果を他の加工法へ適用し、データ駆動型ものづくりを展開していく。手軽に低コストで加工条件出し工程のDXを試みたいと考えている企業の支援を積極的に行っていきたい。

■ 本件問い合わせ先 ■

国立研究開発法人 産業技術総合研究所

製造技術研究部門 素形材加工研究グループ

研究員 権藤 詩織

〒305-8564 茨城県つくば市並木 1-2-1 つくば東事業所

TEL:029-860-5102 FAX:029-861-7129

E-mail: shiori-gondo@aist.go.jp

製造技術研究部門 素形材加工研究グループ

テクニカルスタッフ 荒井 裕彦

〒305-8564 茨城県つくば市並木 1-2-1 つくば東事業所

TEL:029-861-7088 FAX:029-861-7129

E-mail: h.arai@aist.go.jp

【取材に関する窓口】

国立研究開発法人 産業技術総合研究所 広報部 報道室

〒305-8560 茨城県つくば市梅園 1-1-1 中央第1

つくば本部・情報技術共同研究棟

TEL:029-862-6216 FAX:029-862-6212 E-mail:hodo-ml@aist.go.jp

【用語の説明】

◆塑性加工

材料の塑性変形(弾性限を超えた応力下で物体の形状が永久変化を起こす現象)を利用して、金属などの各種材料を所定の形状・寸法に加工する方法の総称。

◆ニューラルネットワーク

脳の仕組みを基に、ノードと呼ばれる単純な計算を行う要素をネットワーク上に組み合わせた機械学習モデル。

◆反復解法

適当な入力初期値から出発し、随時入力値を更新することで最終的な最適解に収束させる計算方法。

◆DX(デジタルトランスフォーメーション)

ものづくりの分野では、加工中や加工後、部品組み立て中などに計測したデータを蓄積し、これらを積極的に使って、開発スピードの向上やリードタイムの削減に活用する取り組みや、経験豊富な人材が持つ技術やノウハウをデータとして蓄積し、新しい人材の育成や工程の機械化に生かす取り組みなどを指す。製造工程のデジタル化とそのデジタルデータを活用して、これまでの課題の解決を行う活動をいう。

日本塑性加工学会 プロセス可視化・知能化分科会
第7回技術セミナー 2023.4.19

機械学習を用いた
絞りスピニングにおける
板厚制御

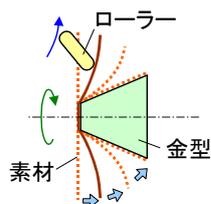


株式会社 大東スピニング
国立研究開発法人 産業技術総合研究所
荒井 裕彦

講演の内容

- スピニング加工
- 開発の背景
- ローラパス生成システム
- 実験結果
- 素板・金型の寸法変動への対応

スピニング加工



- 金属の塑性加工の一手法
- 回転する成形型(マンドレル)に板状や管状の素材(ブランク)を加工ローラやへらで押し付けて成形

スピニング加工の特長

- 成形型が一つだけ ...型コスト低い, 立ち上げ早い
- 低い加工力(局所変形)...低騒音・低振動, 装置も小型
- 材料の節約
- プレス加工で成形不可能な形状にも対応
- 高精度, 良好な表面性状

多品種少量生産, 高付加価値

→量産品もあり

スピニング加工の用途

自動車部品, 宇宙航空部品,
化学産業, 空調機器, 圧力容器,
食品産業, 調理器具, 照明器具,...

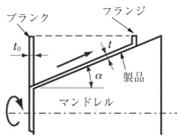
先端産業を支える基盤製造技術の一つ



講演の内容

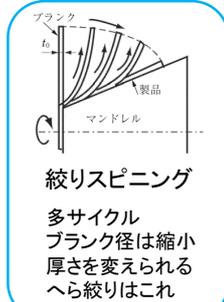
- スピニング加工
- 開発の背景
- ローラパス生成システム
- 実験結果
- 素板・金型の寸法変動への対応

板材のスピニング加工



しごきスピニング

単一パス
ブランク径は一定
厚さ $t = t_0 \sin \alpha$ (sine則)
円筒は不可



絞りスピニング

多サイクル
ブランク径は縮小
厚さを変えられる
へら絞りはこれ

本日のテーマ

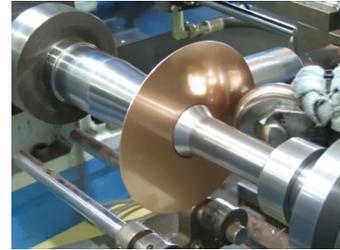
(日本塑性加工学会編 塑性加工便覧より)

絞りスピニング：古くからある基本的な加工法

◎絞り方で成形品の板厚を変えられるが...

システムチックな板厚制御方法：**未確立**

経験に依存(へら絞り, 教示再生式加工機)



教示データによる銅製タンブラーの加工

加工プロセス設計：
成形品の仕様(高さ, 板厚分布, ...) **未解決** ⇔ ローラパス

加工の自由度が高い
= 非常に多数の加工パラメータ

どのように決めるか?

従来の研究(FEMシミュレーションなど)

少数のパラメータのみ **熟練技能や専門知識が不要**
板厚との関係：定性的 **マニュアルに沿ってデータ収集・ソフトウェアを適用**

目標：**誰にでもできる**
定型的な手順でローラパスを決定
手段として機械学習を利用
⇒ **ローラパス生成システム**

講演の内容

- スピニング加工
- 開発の背景
- ローラパス生成システム
- 実験結果
- 素板・金型の寸法変動への対応

ローラパス生成システム

対象：円筒カップ形状の絞りスピニング

- 1) 多サイクルのローラパスを複数のパラメータで表現 (例: パス回数, パス寸法, フィード比, ...)
- 2) 成形品の加工結果を複数の特性値で表現 (例: 成形品高さ, 板厚1, 板厚2, ...)
- 3) パスパラメータと特性値の入出力関係をモデル化 (成形実験 → 機械学習)
- 4) 目標仕様の特性値を満たすパスパラメータを逆算 (数値解法)

成形品の仕様 ⇒ ローラパス

ローラパス生成システム

- 1) パスパラメータ: 入力ベクトル $p = (p_1, p_2, \dots, p_n)$
- 2) 成形品の特性値: 出力ベクトル $q = (q_1, q_2, \dots, q_m)$
- 3) 入出力関係: 多変数ベクトル関数 $q = f(p)$
機械学習による推定値: $q = \hat{f}(p)$
- 4) 成形品の仕様: 目標ベクトル q_d

プロセス方程式 $q_d = \hat{f}(p)$ を未知数 p に関して解く

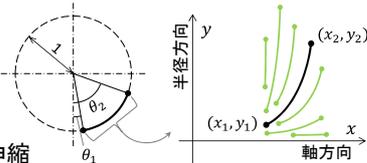
ローラパスのパラメータ表現

加工開始から終了までの1セットのローラパス
 → 複数のパラメータで表現
 ◎ しわや破断などが起きず成形可能なパスを含むこと
 ◎ 十分多様な特性の成形品が成形できること

直線パス要素 + 曲線パス要素 で構成

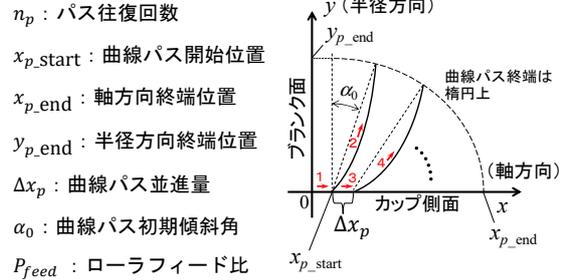
曲線パス: 下に凸
 (concave形状)
 ...しわが生じにくい

単位円弧を縦横に伸縮



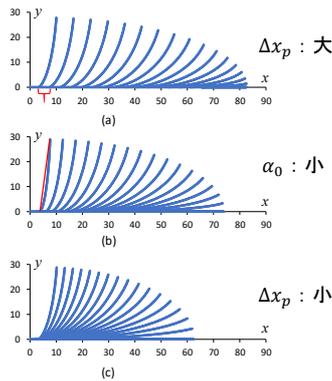
パスパラメータの構成

加工開始から終了までの1セットのローラパス



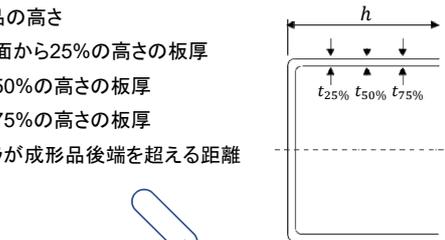
パスパラメータ ⇒ ローラ制御のNCプログラムを生成

生成されるローラパスの例



成形品の特性値の定義

h: 成形品の高さ
 t_{25%}: 底面から25%の高さの板厚
 t_{50%}: 同50%の高さの板厚
 t_{75%}: 同75%の高さの板厚
 rp: ローラが成形品後端を超える距離



プラス: 加工時間のロス
 マイナス: フランジ形成

機械学習による加工プロセスの予測モデル

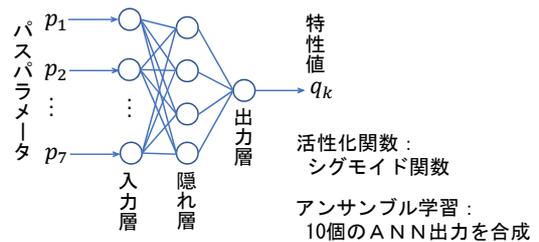
成形実験の結果
 ⇒ ニューラルネットワーク (ANN) で学習

パスパラメータ p と特性値 q の関係
 $q = f(p)$ を推定する関数 f を構築

FEMシミュレーションでも理論的には可能だが
 計算時間の点で非実用的 (反復計算への使用)

多層パーセプトロン (MLP)

任意の非線形関数を近似可能
 教師付き学習: バックプロパゲーション
 汎化能力 (データの空白を滑らかに補間/補外) → 予測



反復計算によるプロセス方程式の数値解

方程式 $q_d = \hat{f}(p)$ を未知数 p に関して数値的に解く

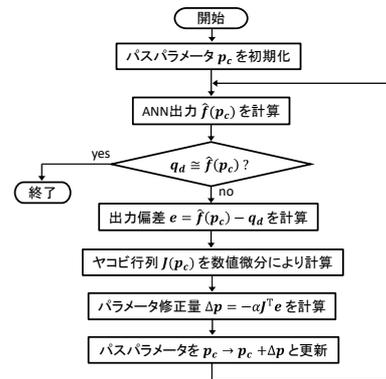
◎最急降下法を適用

関数 $\hat{f}(p)$ の p に関する偏微分 $J = \frac{\partial q}{\partial p} = \frac{\partial \hat{f}(p)}{\partial p}$ (ヤコビ行列)

〔数値微分 $\frac{\partial \hat{f}_j(p)}{\partial p_k} = \frac{\hat{f}_j(p_1, \dots, p_k + \epsilon, \dots, p_n) - \hat{f}_j(p_1, \dots, p_k - \epsilon, \dots, p_n)}{2\epsilon}$ で近似〕

入力・出力の現在値から入力の微小変化を求め→反復計算

- ①出力偏差 $e = q - q_d = \hat{f}(p) - q_d$
- ②入力の微小変化 $\Delta p = -\alpha J^T e$ (α は係数)
- ③入力を $p + \Delta p$ に更新
- ④出力偏差 e が十分小さくなるまで①～③を繰り返す



計算時間の例

- ・ ANN学習: 15 sec
(7入力5出力MLP, 隠れ層1層6ノード, 学習データ72組
BPアルゴリズム5000回反復, アンサンブル学習 ANN×10)
- ・ ANN予測: ~0.1 msec ⇔ FEMシミュレーション 345 h (Li 2019)
(入力10000組で1sec以内)
- ・ 数値解法: 約0.1 sec
(解72組で 6.6 sec, 平均反復回数191回
収束しないものを除く)

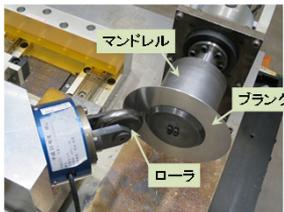
Windowsパソコン(Core i7-4790)使用
C言語, 自作プログラム

講演の内容

- ・ スピニング加工
- ・ 開発の背景
- ・ ローラパス生成システム
- ・ 実験結果
- ・ 素板・金型の寸法変動への対応

実験装置の構成

加工機: リニアモータ駆動スピニング加工機 (定格推力1kN)
ローラ: φ70mm, 丸みR8mm, 傾斜角45°, SKD11焼入
マンドレル: 円柱形状, φ85mm, 高さ90mm, S45C焼入
ブランク: アルミニウム (A1050-0), φ150mm, 板厚1.49mm



成形品高さ: ハイトゲージで測定
成形品板厚: マイクロメータで測定

実験(1) ANNによる特性値の推定

◎パスパラメータからANNで成形品の特性値を予測可能なことを検証する

- ・ 成形実験によるデータ収集

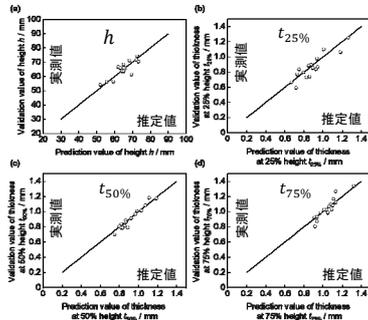
データ群A (18組) ... ANN学習用
実験計画法のL18直交表を部分的に乱数化

データ群B (17組) ... ANN検証用
一様乱数によるパラメータ

パスパラメータの範囲

| パラメータ | n_p | $x_{p,start}$ | $x_{p,end}$ | $y_{p,end}$ | Δx_p | α_0 | P_{feed} |
|-------|-------|---------------|-------------|-------------|---------------------------------------|------------|------------|
| 最小値 | 13 | 0 | 57.9 | 24 | 0 | 0 | 0.8 |
| 最大値 | 26 | 8 | 97.8 | 34 | $\frac{x_{p,end} - x_{p,start}}{n_p}$ | 20 | 2.4 |

データ群AでANNを学習
 データ群BのパスパラメータをANNに入力
 → 推定値と実測値を比較



推定値の実測値に対する二乗平均平方根誤差 (RMSE) および決定係数 (R^2)

| | 高さ | 板厚 | | |
|-------|------|------------|------------|------------|
| | | $t_{25\%}$ | $t_{50\%}$ | $t_{75\%}$ |
| RMSE | 2.93 | 0.07 | 0.04 | 0.05 |
| R^2 | 0.71 | 0.79 | 0.93 | 0.83 |

ANNによる推定値と実測値の一致は良好

パスパラメータと成形品の特性値の関係：
 ANNによって適切にモデル化

実験 (2) ローラパス生成システムによる板厚制御

◎板厚などの特性値に目標値を設定し、数値解法により目標値を実現するパスパラメータを求める

ANNの学習：

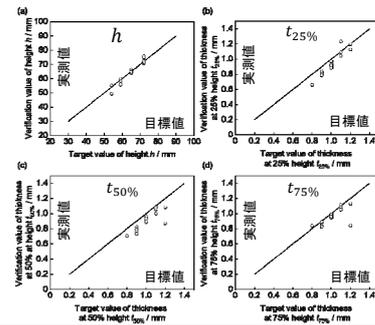
実験 (1) のデータ群 A+B (35組) を使用
 予測精度向上のためにデータ数を増やす

目標値の設定：

板厚：板厚一定 ($t_{25\%} = t_{50\%} = t_{75\%}$)
 0.6~1.2mm (0.1mm毎) 7通り
 高さ：円筒側面が一定かつ目標値の板厚となる高さ
 余剰パス長：0

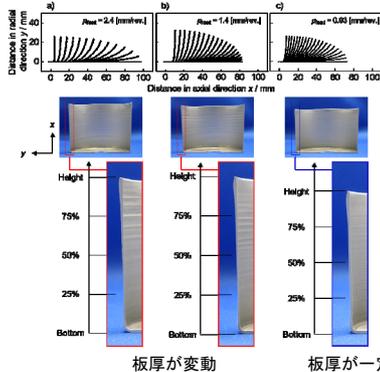
数値解法の結果：

目標板厚0.8mm以上でANN推定値が目標値に収束する
 パスパラメータ (22組) が得られた
 成形実験 → 目標値と実測値を比較



ローラパスと成形品断面の例

a),b) 学習データ c) 板厚制御の結果



実測値の目標値に対する二乗平均平方根誤差 (RMSE)

| | 高さ | 板厚 | | |
|------|------|------------|------------|------------|
| | | $t_{25\%}$ | $t_{50\%}$ | $t_{75\%}$ |
| RMSE | 1.87 | 0.086 | 0.013 | 0.094 |

おおむね目標値に近い板厚や高さが得られる

ローラパス生成システムにより最大0.1mm
 以内のRMSEで板厚制御が実現できた

講演の内容

- スピニング加工
- 開発の背景
- ローラパス生成システム
- 実験結果
- 素板・金型の寸法変動への対応

ブランク・マンドレルの寸法：1種類の組合せ



様々な寸法の組合せで成形を行うことが必要

寸法毎に独立にANN学習
⇒ 蓄積された別の寸法の学習データを有効利用

目標：

未学習のブランク・マンドレル寸法に対して、異なる寸法のブランク・マンドレルによる学習結果に基づいて、成形結果の予測や制御を実現

ANNの汎化能力を利用

固定パラメータの追加による拡張

パスパラメータ(可変): $p = (p_1, p_2, \dots, p_i)$
 固定パラメータ: $r = (r_1, r_2, \dots, r_j) \dots$ 寸法パラメータ (追加)
 ⇒ ANNへの入力ベクトル: (p, r)

成形品の特性値: 出力ベクトル $q = (q_1, q_2, \dots, q_m)$

入出力関係: 多変数ベクトル関数 $q = f(p, r)$

ANNを p, r, q の組合せのデータ群で学習

⇒ ANNIによる推定値: $q = \hat{f}(p, r)$

固定パラメータを含む場合の数値解法

方程式 $q_d = \hat{f}(p, r)$ を未知数 p に関して数値的に解く

固定パラメータ r を変化させず、可変パスパラメータ p だけを変化させることが必要

関数 $\hat{f}(p, r)$ の p に関する偏微分 $J_p = \frac{\partial q}{\partial p} = \frac{\partial f(p, r)}{\partial p}$ (部分ヤコビ行列) を用いる

反復計算

- ①出力偏差 $e = q - q_d = \hat{f}(p, r) - q_d$
- ②入力の微小変化 $\Delta p = -\alpha J_p^{-T} e$ (α は係数)
- ③入力を $p + \Delta p$ に更新
- ④出力偏差 e が十分小さくなるまで①~③を繰り返す

実験(3) 未学習のブランク・マンドレル寸法に対する特性値の推定

ブランク直径: D マンドレル直径: d

学習データ: $(D, d) = (90, 50), (110, 50), (130, 85), (150, 85)$

L8直交表に基づくパスパラメータで8組ずつ成形実験

⇒ パスパラメータ, 寸法パラメータ, 特性値の組合せでANNを学習

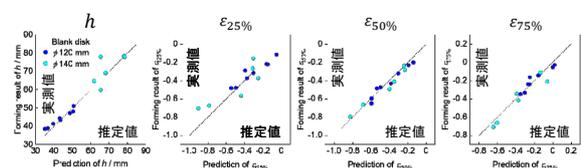
検証データ: $(D, d) = (120, 70), (140, 70) \dots$ 未学習の寸法

L8直交表に基づくパスパラメータで8組ずつ成形実験

⇒ パスパラメータ, 寸法パラメータをANNに入力して得られる推定値を実測値と比較

(特性値として板厚の代わりに板厚歪み $\varepsilon_{25\%}, \varepsilon_{50\%}, \varepsilon_{75\%}$ を使用)

推定値と実測値の比較



二乗平均平方根誤差 (RMSE) および決定係数 (R^2)

| | 高さ h | 板厚歪み | | |
|-------|--------|----------------------|----------------------|----------------------|
| | | $\varepsilon_{25\%}$ | $\varepsilon_{50\%}$ | $\varepsilon_{75\%}$ |
| RMSE | 4.0 | 0.097 | 0.047 | 0.060 |
| R^2 | 0.92 | 0.70 | 0.90 | 0.91 |

異なる寸法のブランク・マンドレルによる学習データに基づいて未学習の寸法の成形結果が予測できた

実験 (4) 寸法混合のブランク・マンドレルによる学習データに基づく板厚制御

学習データ:

$(D, d) = (90, 50), (110, 50), (130, 85), (150, 85), (120, 70), (140, 70)$

⇒ 8組ずつの成形実験の結果でANNを学習

制御対象:

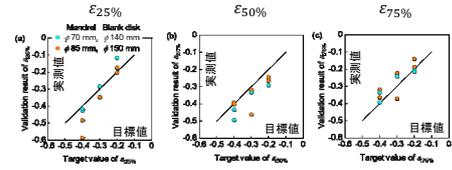
ブランク・マンドレル寸法設定 $(D, d) = (150, 85), (140, 70)$

板厚歪みの目標値 $\varepsilon_{25\%} = \varepsilon_{50\%} = \varepsilon_{75\%} = -0.2, -0.3, -0.4$

ローラパス生成システムでパスパラメータを求める

⇒ 成形実験の実測値を目標値と比較

目標値と実測値の比較



二乗平均平方根誤差 (RMSE)

| RMSE | 板厚歪み | | |
|------|----------------------|----------------------|----------------------|
| | $\varepsilon_{25\%}$ | $\varepsilon_{50\%}$ | $\varepsilon_{75\%}$ |
| | 0.069 | 0.070 | 0.053 |

寸法混合の学習データに基づいて板厚歪みの制御がおおむね実現できた

冗長性: 同じ目標値に対して複数のパスパラメータ
多くは目標値に近いが外れる場合がある (モデルの推定誤差)

[今後の課題]

- ANNの推定精度, 数値解法の収束性の向上
- ローラパスの多様化(往復パスなど)
- ローラ寸法など加工条件の追加
- 異なる材料への展開
- 円筒以外の形状への対応
- 異形スピニングへの適用
- 他工法への方法論の波及

