インクリメンタルフォーミングにおける高加工精度の工具経路を生成するAIシステムの開発

福井大学　学術研究院工学系部門　機械工学講座
教授　大津　雅亮
（2020年度 重点研究開発助成 課題研究 AF-2020004-A3）

キーワード：インクリメンタルフォーミング，ツールパス，ニューラルネットワーク

１．緒言

インクリメンタルフォーミングは金型を使用せずに板材を三次元成形できるため，多品種少量生産に適している．しかし，金型を使用しないために板材の拘束が弱く，スプリングバックによって成形精度はあまり高くない．そこで，成形後にスプリングバックした形状が求める形状となるように，目標形状のツールパスではなく，スプリングバック後に目標形状になるようなツールパスを求める必要がある．インクリメンタルフォーミングのプロセスをシミュレーションするには膨大な時間がかかるため，シミュレーションでこの修正したツールパスを求めるために思考錯誤するのは現実的ではない．

一方で，近年のAI技術の発展により様々な分野でAI技術が利用されるようになっている．AI技術の一つであるニューラルネットワークは，入力情報と出力情報の関係が明確な物理モデルに基づいたものではないため，ブラックボックスであると言われることもあるが，モデル化が困難な複雑な事象に対して，ある程度の精度で入力情報から出力情報を得ることができる．

本研究では，インクリメンタルフォーミングにおいてスプリングバック後に目標形状となるようなツールパスを作成するニューラルネットワークを構築することを目的とした．ツールパスから成形形状を求めて，ツールパスを修正するような試行錯誤をするのではなく，逆問題として成形形状を入力してツールパスを出力することとした．

２．実験方法

２・１　成形方法及び成形条件

3軸立形マシニングセンタ(MILLAC44VⅡ，オークマ社製)を用いて円錐台形状を成形した．工具にはSKH51，直径6 mmの先端が半球状の棒状ツールを使用した．図1にツールパスを示し，図2に成形高さ，成形角度，初期直径の定義を示す．また，成形条件を表1に示す．

供試材には寸法150 mm × 150 mm × 0.5 mmのA5052-H34材，SUS304-No2B材，SPCC材を用いた．

２・２　形状測定方法

成形品の形状測定には，3次元変形計測器(ARAMIS，GOM社製)を使用した．ARAMISで撮影した画像からSTLデータを作成後，目標形状のSTLデータと比較し，隙間体積が最小となるように底面合わせを行い，断面形状を抜き出した．

円錐台の側壁付近において連続する5点のデータをもとに近似直線をとり，近似直線の傾きから必要な傾斜角を求めて，成形角度との大きさが±5°以内となる部分を側壁部分と定めた．さらに側壁部分の中で最も外側の5点を求め，それぞれの3点目を成形高さと初期直径の基準点とした．

２・３　ニューラルネットワークのモデル

時系列ではツールパスを決定して加工し，成形形状を得るため，目標形状を得るためにツールパスは成形後の形状を用いて修正することを繰り返す必要がある．しかし，本研究では直接修正後のツールパスを得るために，使用したツールパスを出力，成形形状を入力とした逆問題として扱った．

抜き出した断面形状から教師データを作成した．成形形状の教師データは，円錐台の中心から側壁までの距離と底

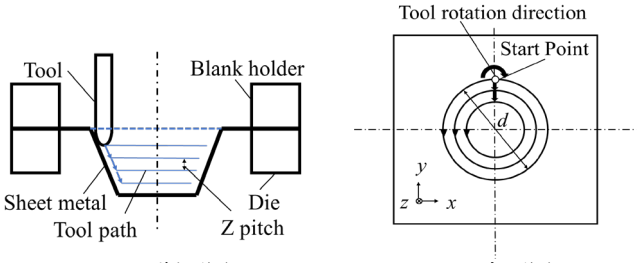

(a) 断面図　(b) 上面図

図1　ツールパス

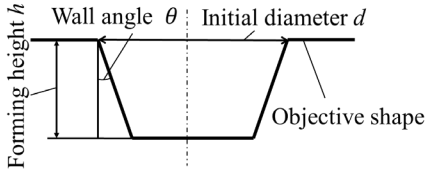

図2　成形高さ，成形角度，初期直径の定義

表1　ニューラルネットワークのパラメータ

入力層のノード数 x	40, 80
出力層のノード数 w	80, 160
中間層数	1, 2
中間層のノード数 y, z	1000 - 5000
エポック e	1000 - 20000
最適化法	Adam[1] ($\alpha = 0.001$, $\beta_1 = 0.9$, $\beta_2 = 0.999$)
活性化関数	Swish[2], Relu, Sigmoid, Tanh
誤差関数	MSE, MAE, Huber

面からの高さを成形高さによって決められた数だけ抜き出した．断面形状から側壁の座標を成形高さが 25 mm の時は 25 点，30 mm の時は 30 点，35 mm の時は 35 点を抜き出し，成形高さが 35 mm に達していないときは座標として(0, 0)を挿入した．必要に応じて材料特性を表すパラメータとして板材の降伏応力とヤング率の比を入力層に入力した．加工パスの教師データは，断面を通過した点の中心からの距離とそのときの工具の Z 方向の座標を入力した．

3．実験結果

3・1　データ作成および活性化関数

形状の教師データは 6 パターン作成した．パターン(a)は側壁部の座標の間隔が最も広くなるように 20 点抜き出した．パターン(b)では，成形高さと同じ数だけ点を抜き出し，成形高さが 40 mm に達していないときは(0, 0)を挿入した．パターン(c)は加工経路と同じ z 座標の値を用いることで z 座標の値の入力を略した．同じ z 座標の値とするために線形補完を用い，加工経路に存在しない座標の場合 0 を挿入した．パターン(a’)，(b’)，(c’)はそれぞれパターン(a)，(b)，(c)を以下の式に従って正規化したものである．

$$x_i' = (x_i - x_{min}) / (x_{max} - x_{min})$$

加工パスの教師データは断面を通過した点の中心からの距離とその時の工具の Z 方向の座標とした．成形高さが最大のときとノード数を合わせるため，実際に加工していない場合には(0, 0)を挿入している．テストデータに傾斜角 θ ＝ 45°，成形高さ h = 25 mm，初期直径 d = 80 mm を用いた．また，検証のため教師データにない未知の条件の θ ＝ 43°，h = 23 mm，d = 78 mm の加工パスを出力した．本実験では活性化関数に Swish，Relu，Sigmoid，Tanh を用いた．詳細なパラメータを表 1 に示す．

図 3 にニューラルネットワークによるテストデータの加工パス出力結果を示す．図 3(ⅱ)ではパターン(b)のみ加工パスが一本の線にはならず，テストデータの再現ができていない．しかしパターン(b)を正規化したパターン(b’)は再現性を獲得している．このことから正規化は再現性の獲得に寄与していると考えられる．

図 4 に未知の目標形状に対してニューラルネットワークに出力させた加工パスで成形した成形品の形状を示す．断面を比べると，図 4(ⅰ)のパターン(a)，パターン(c)は通常手法より精度よく成形できている．一方，正規化したパターン(a’)，パターン(c’)は正規化前より精度が悪化している．以上より正規化は汎化の獲得に有効とはいえない．

図 5 に活性化関数による加工パスのパターン(a)のモデルの出力結果の違いを示す．図 5(i)より，Relu は再現性を獲得しているがその他は再現性を得ていない．また，図 5(ii)より，Relu は汎化を獲得している．

図 6-8 に通常手法，パターン(a)，パターン(c)の成形品

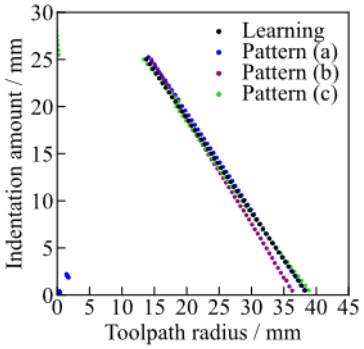

(i) 出力パターン(a)-(c)

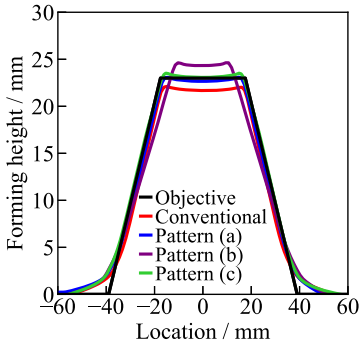

(i) パターン(a)-(c)の成形形状

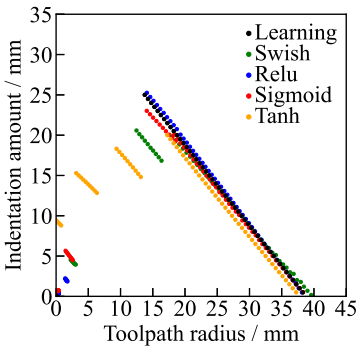

(i) 活性化関数によるパターン(a)の訓練データの出力比較

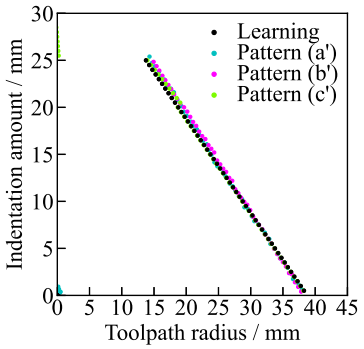

(ii) 出力パターン(a') - (c')

図 3　訓練データの出力比較

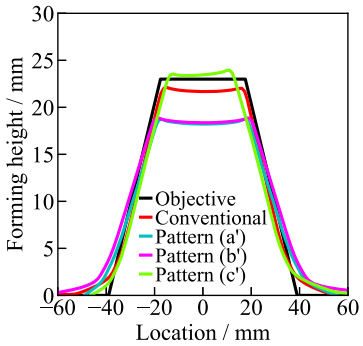

(ii) パターン(a')-(c')の成形形状

図 4　成形形状の比較

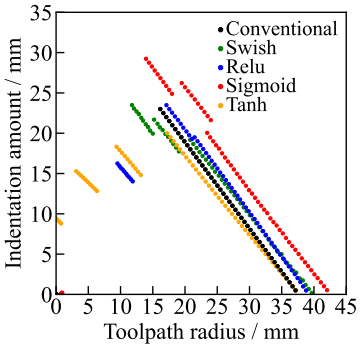

(ii)活性化関数によるパターン(a)の未知形状に対する出力の比較

図 5　活性化関数による出力の比較

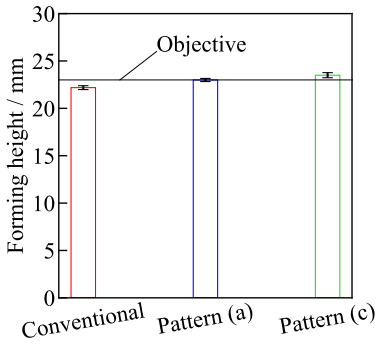

図 6　成形高さの精度

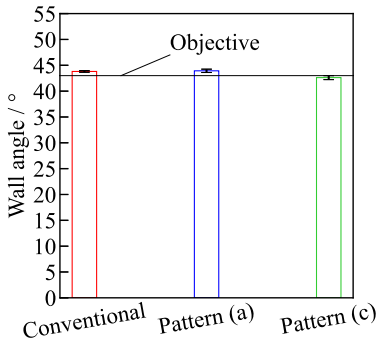

図 7　成形角度の精度

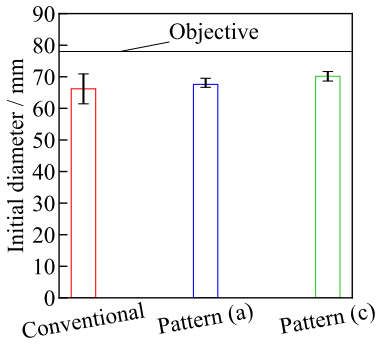

図 8　初期直径の精度

の成形高さ，傾斜角，初期直径の成形精度を示す．成形高さ，傾斜角は非常に精度良く成形できている．また，パターン(c)によって生成された加工パスの成形品は通常の手法に比べてすべての項目で精度よく加工できており，総合的に最も精度の良いモデルであった．

3・2　材料特性の影響

材料特性を考慮したモデル(a)，材料特性を考慮しないモデル(b)，材料ごとに学習を行ったモデル(c，d，e)の複数のモデルを用いた．中間層の活性化関数には ReLU 関数，出力層には線形関数を用いた．学習の最適化アルゴリズムには Adam2($\beta 1 = 0.9$，$\beta 2 = 0.999$)を用いた．材料特性を表すパラメータとして板材の降伏応力とヤング率の比を追加した．表 2 に使用した材料特性値を示す．

材料特性を入力したモデル(a)と材料特性を入力せず，すべて材料の形状を教師データとして学習させたモデル(b)の出力された加工パスと加工した成形形状と成形精度の比較を行った．

加工パスが未知の目標形状（$\theta = 43°$，h = 28 mm，d = 78 mm）を入力し，加工パスを出力した結果を図 9 に示す．また，断面形状の比較を図 10 に示す．目標形状に対して加工可能な加工パスを材料ごとに出力でき，断面形状も目標に近い結果となった．

図 11 に材料ごとに加工後の成形品と目標形状との隙間体積を示す．成形品と目標形状の隙間体積の比較から A5052 では約 8%，SUS304 では約 14%，SPCC では約 12%と材料特性を考慮したモデルの結果の方が隙間体積の値が減少しており，成形精度が向上した．

次に材料特性を考慮したモデル(a)と A5052 のみのモデル(c)，SUS304 のみのモデル(d)，SPCC のみのモデル(e)との比較を行った．図 12 に加工した成形品の隙間体積の大きさを示す．各材料のみのモデル(c，d，e)と比べて材料特性を考慮したモデル(a)の方が A5052 では約 10%，SUS304 では約 14%，SPCC では約 10%小さくなり，成形精度が良くなった．

材料特性を考慮したモデル(a)に目標形状と熱処理を施した A5052 のパラメータを入力した．得られた加工パスをもとに加工した成形品と材料特性を考慮しないモデル(b)に目標形状を入力し，得られた加工パスをもとに加工した成形品と A5052 のみのモデル(a)に目標形状を入力し，得られた加工パスをもとに加工した成形品との比較を行った．図 13 に加工パスの比較結果を示す．教師データに含まれていない材料であっても材料特性の値を用いて加工可能な加工パスを作成することが可能だった．また，図 14 に計測した断面形状の比較，図 15 に加工した成形品の隙間体積の大きさを示す．教師データにない材料も材料特性を考慮したモデル(a)の成形精度が一番高くなった．さらに，教師データに含まれていない材料も材料特性値から成形精度が高い加工パスを作成することが可能だった．各モデルの細かな結果の違いには教師データ数の違いや材料特性の有無が考えられるため，今後さらなる検証が必要である．

3・3　正多角錐台形状への拡張と成形面の平滑化

円錐台形状をもとに正多角錘台形状への拡張を行った．図 16 に示すように位置合わせ後の Z 座標と，Z 座標における XY 平面の外接円の半径長さを形状データとし，モデルの学習に使用した．断面形状は位置合わせをした後，各

表 2　使用した材料のヤング率と降伏応力 s

Material	Young's modulus E /GPa	Yield stress Y (0.2% proof stress) /MPa	Y/E /×10^{-3}
A5052	70	203	2.90
SUS304	197	336	1.70
SPCC	192	172	0.895
A5052-O	70	91.9	1.31

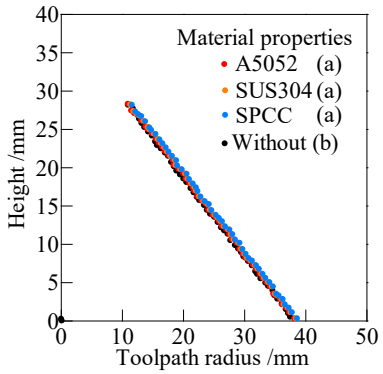

図 9　材料ごとの出力されたツールパス

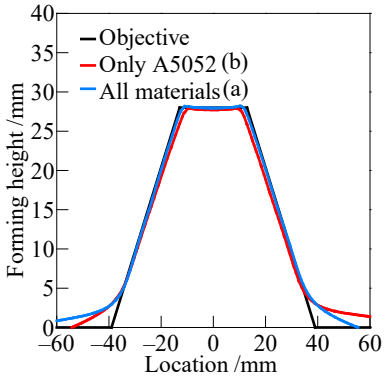

図 10　A5052 の成形品の断面形状

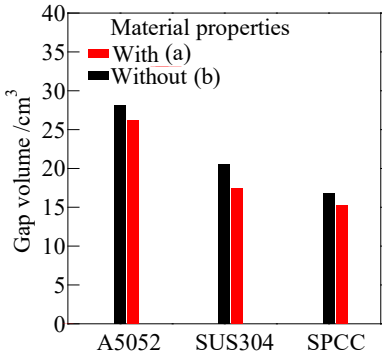

図 11　材料特性の考慮の有無による隙間体積の比較

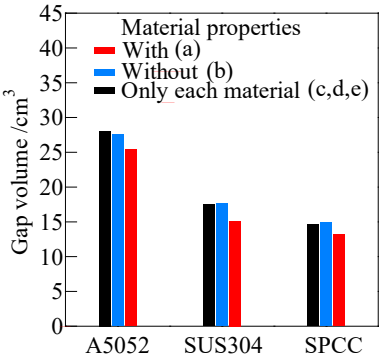

図 12　各材料特性のみと全材料特性を考慮した時の隙間体積の比較

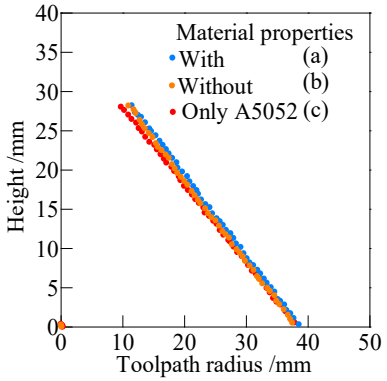

図 13　出力されたツールパス

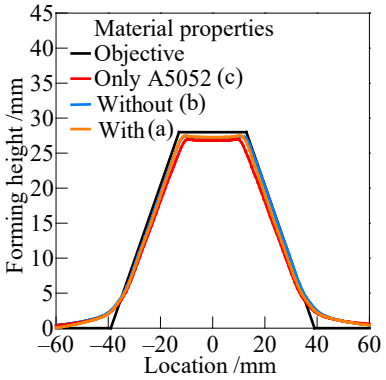

図 14　成形品の断面形状

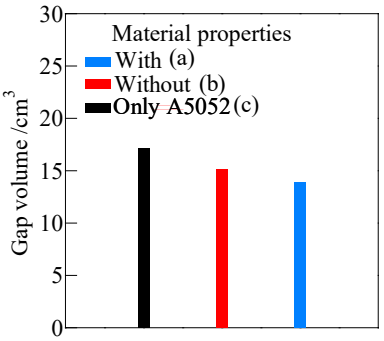

図 15　A5052 の材料特性考慮による隙間体積の比較

成形品の各側壁付近において，連続する 5 点のデータをもとに，近似直線をとり，傾斜角との大きさが±5° 以内となる部分を側壁部分と定めた．位置合わせ後の高さ 0 から各成形品の側壁の最大の高さを 50 分割することで，断面を抜き出した．断面は位置合わせ後に定まった断面の中心から，断面の各点までの距離を求めた．距離のばらつきを考慮し，距離の平均から標準偏差+σ ～ +2σ のそれぞれ範囲内の距離を求め，範囲内の距離の平均値を各断面の外接円の半径方向の長さ r とした．またフランジ部分では，だれ変形の影響で該当する距離がない場合があったため，線形補間を行った．

NN において中間層の活性化関数には ReLU 関数，出力層の活性化関数には Linear 関数を使用した．また外接円の半径長さと Z 座標を入力層，加工パスの各断面の外接円の半径長さと一周当たりの Z 方向の押込み量を出力層として学習を行った．成形高さと一周当たりの Z ピッチの長さの関係より，最大で 80 周である為，出力層のノードは 160 とした．また加工パスが 80 周に満たない場合，外接円の半径長さ，Z 座標に存在しないと解釈される 0 を入れ，ノードの数を統一した．

モデルの精度の評価は，実際に成形された形状をテストデータとしてモデルに入力し，出力された加工パスと元の加工パスを比較した．次に出力された正四，五，六角錐の未知の目標形状に対して出力した加工パスと，それぞれを 4 次曲線で近似した加工パスを実際に成形し，従来の加工パスによる成形品と成形精度を比較した．

実際に成形された形状（N = 4，d = 80 mm，h = 30 mm，θ =40°）をテストデータとし，テストデータを成形するため，従来の加工パスと NN によって生成された加工パスを比較した結果を図 17 に示す．テストデータと教師データはほぼ一致しており，再現性が高く，正しい学習が行われていた．

未知の目標形状（d = 78 mm，h = 26 mm，θ = 46°）に対して出力された四角錐の加工パスと，出力された正四，五，六角錐の加工パスを 4 次式で近似した加工パスを比較した結果を図 18 に示す．同モデルに対し，どの形状においても，実際に成形可能な加工パスが生成された．

図 19 には従来の加工パスによって成形された正四，五，六角錐の成形品と，NN によって出力された各加工パスに

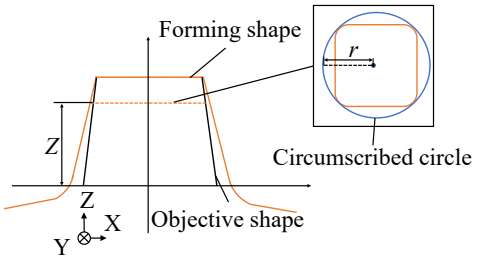

図 16　円錐台をもとにした多角錘台のモデル化

よって成形された成形品の目標形状との最小の隙間体積を比較した結果を示す. 正四角錐に対して出力された加工パスを 4 次式で近似した場合，隙間体積が約 10.6 %減少した．また，正六角錐に対して出力された加工パスを 4 次式で近似した場合，隙間体積が約 3.38 %減少した．よって同モデルで複数の正多角錐の精度が向上した.

図 20 に最も隙間体積が減少した，四角錐に対して出力された加工パスを 4 次式で近似した加工パスによって成形された形状の(a) X 軸方向の断面と，(b) XY 平面における斜め方向の断面を示す. X 軸方向の断面では，NN によって出力された加工パスによって成形した形状の方が，だれ変形付近でより目標形状に近い形状となった. またいずれも NN によって出力された加工パスによって成形した形状の方が，より目標形状に近い形状となった.

図 21 には未知の目標形状に対して出力された正四角錐の加工パスによって成形された成形品と，4 次式で近似した加工パスによって成形された成形品を比較した結果を示す. 出力された加工パスを 4 次式で近似した方がより滑らかな側壁となった.

3･4　深度画像を用いた畳み込みニューラルネットワークを用いた方法

測定した 3D 形状データは，CAD で作成した目標形状との隙間体積が最小となるように位置合わせを行い，図 22 に示すように成形品の z 軸方向の高さ分布をまとめたもの(深度画像)を CNN の入力に用いた. 入力データの解像度を 50 pixel × 50 pixel，100 pixel × 100 pixel，200 pixel ×200 pixel と変えた 3 つの CNN モデルを作成し，それぞれ Model50，Model100，Model200 とした.

CNN の出力データは，成形品の x-z 断面における工具先端が通過する点の座標とし，等高線上を円周加工する際の対称軸からの距離のみを用いた. 教師データに用いた成形品の最大高さ 40 mm に合わせ，出力ノード数は 81 に設定した. 成形高さが 40 mm 未満の成形品ではデータ数が不足するため，不足分は 0 をデータに入力し，ノード数を 81 に揃えた.

本実験では，VGG16[3] と呼ばれる既存のアーキテクチャを参考に CNN モデルを構築した. 68 個の成形品データのうち，64 個を学習用，残りの 4 個をテスト用に無作為に分割し，学習を行った.

学習が完了した CNN に，教師データには用いていない未知の形状データ(h = 23 mm，d = 78 mm，θ = 43°)を入力し，出力された加工パスで加工した成形品と従来の加工パスで加工した成形品の，成形高さ誤差と初期直径誤差を比較して評価を行った.

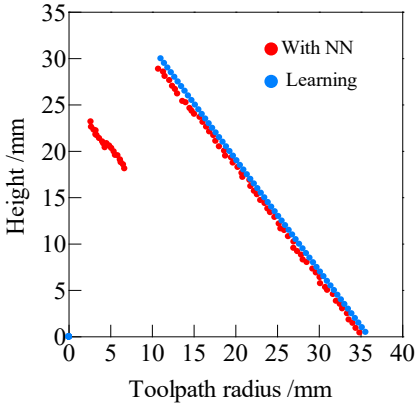

図 17　学習データによるツールパス
(N = 4, d = 80 mm, h = 30 mm, θ = 40 °)

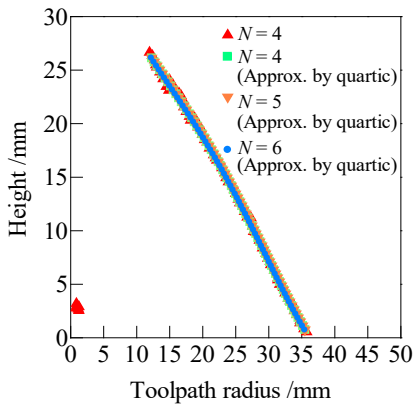

図 18　各多角錘台のツールパス
(d = 78 mm, h = 26 mm, θ = 46 °)

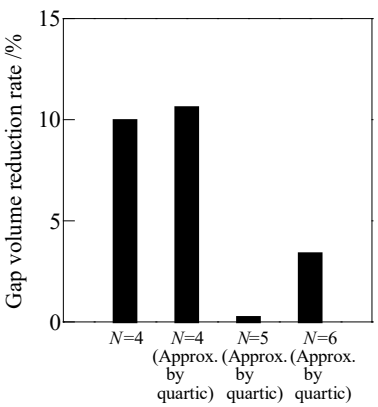

図 19　隙間体積の減少率

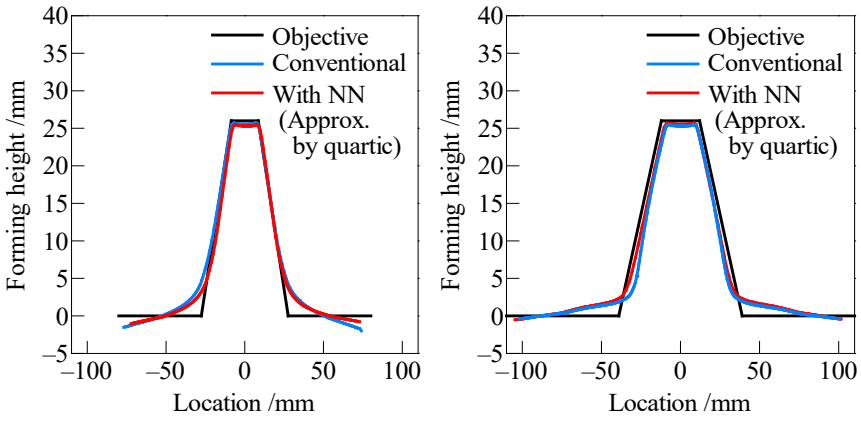

(a) X 軸　　(b) 対角
図 20　ツールパスを 4 次式で近似した時の断面形状の比較

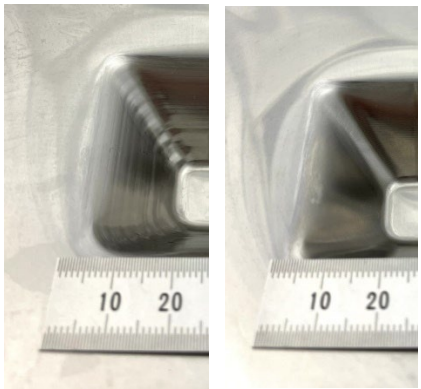
(a) 平滑化なし　　(b) 平滑化あり
図 21　成形品の外観

図 23(a)は CNN から出力された加工パスの出力結果の比較である．どのモデルも加工可能な加工パスが出力できており，従来の加工パスに比べ一回り大きく出力された．

これらの加工パスで成形した断面形状の比較を図 23(b)に示す．どのモデルも従来の加工パスで加工した断面形状に比べて，目標形状に近く成形できている．

また各誤差の評価を図 23(c)に示す．全てのモデルにおいて，従来の加工パスで加工した成形品よりも成形高さ誤差，初期直径誤差が改善した成形品が得られ，特に成形高さにおいては顕著に改善が見られた．これは入力データにおいて，成形高さを表す面積の割合が大きく，CNN が学習の過程で成形高さの特徴を良く抽出することができたからだと考えられる．また，入力データの解像度は，精度の向上にあまり影響はなかった．

本研究で最も評価が高いと判断した Model50 と，先行研究[4]で構築された最も評価の高い NN モデル(以下「ANN」と称する)の結果を図 24 に示す．成形高さ誤差，初期直径誤差の双方において，ANN よりも改善した．これは，前報のモデルでは，成形品の形状データを 1 次元配列に変換して入力する必要があるのに対して，CNN モデルでは成形品の空間情報を保持したまま扱うことができるため，形状データの特徴をよりよく抽出することができたためだと考えられる．

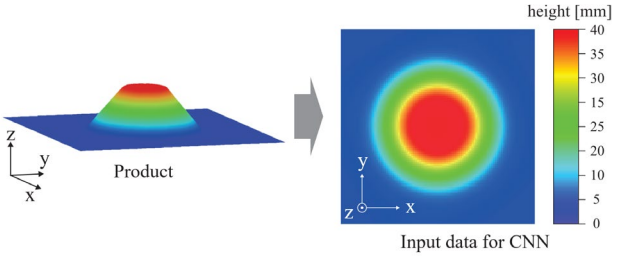

図 22　3D 形状の深度画像への変換

謝　辞

本研究は，公益財団法人天田財団重点研究開発助成の支援を受けて行われたものです．心から感謝を申し上げます．

参考文献

1) Kingma et al.: Proc. Int. Conf. on Learning Representations, (2015).
2) Ramachandran et al., Proc. Int. Conf. on Learning Representations, (2018).
3) Simonyan et al.: Proc. Int. Conf. Learning Representations, (2015), DOI:10.48550/arXiv.1409.1556.
4) 大津ほか: 73 回塑加連講論, (2022), 211.

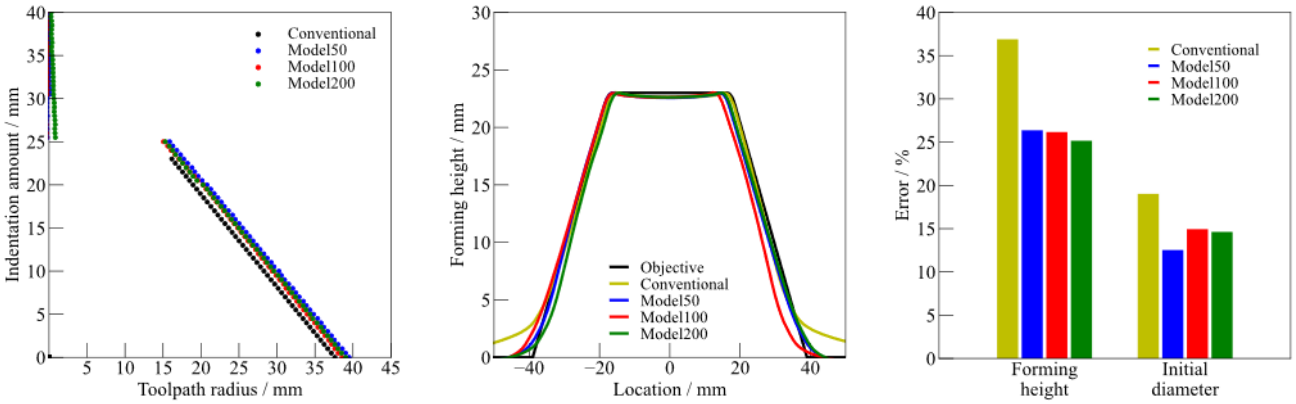

(a) ツールパス　(b) 断面形状　(c) 成形誤差

図 23　CNN によるツールパス，成形形状，成形誤差の比較(h = 23mm, d = 78mm, θ = 43°)

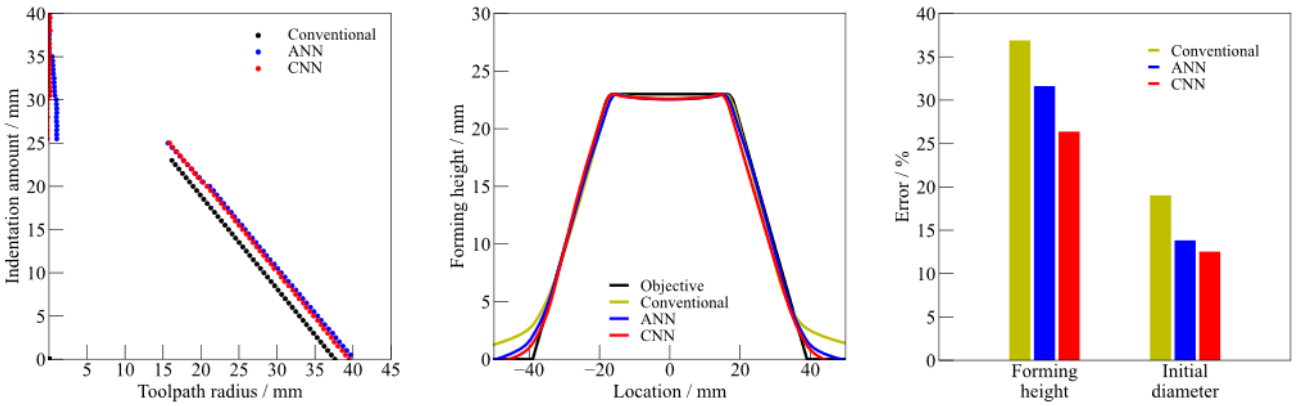

(a) ツールパス　(b) 断面形状　(c) 成形誤差

図 24　ツールパス，成形形状，成形誤差の ANN と CNN による比較(h = 23mm, d = 78mm, θ = 43°)