# 工程数削減を実現するサーボプレスモーションの究明，およびモーション設計支援ツールの開発

産業技術総合研究所　製造技術研究部門
主任研究員　梶野　智史
（2022 年度 重点研究開発助成 課題研究 AF-2022001-A3）

**キーワード**：ニューラルネットワーク，寸法予測，後方押出し

## １．はじめに

サーボプレスはモーションがいろいろと変えられることや繊細な下死点操作などが特徴である．例えば，メカプレスでは再現できないパルスモーションや可変速度のモーション，コイニングモーションなどが挙げられる．それらの特殊なモーションを活用することによって，通常のメカプレスでは加工が困難である形状でも加工できた事例がある [1,2]．また，効果的にモーションを利用することで工程削減につなげられる可能性もある．しかしながら，モーションは経験則に頼ったトライアンドエラーで設計する必要がある一方，経験値自体の蓄積も多くないため，有効なモーションを設計することは困難であり，サーボプレスを容易に活用できていないのが実情である．また，モーションはノウハウを含むものであり，基本的なモーションは公開されているものの，厳密な設定値は非公開であり，各社でデータをそろえ，経験を蓄積するしかない．

そこで，モーションによる寸法を機械学習で予測し，モーション設計に役立てるシステムについて検討した．また，モーションのパラメータ化が出来れば，それによって，加工のデジタル化が促進され，将来的にはデータ駆動型や PI などいろいろな方向に応用できる．

本研究では，サーボプレスの特徴であるパルスモーションに焦点を当てた．パラメータ化できるものからパラメータ化し，寸法変動との相関を機械学習（ニューラルネットワーク）で検証した．ニューラルネットワークの方式は順伝播型（多層パーセプトロン）を用いた．予測できる寸法変動は微小な範囲であるが，微小な寸法変動でも予測ができるならば意味があると考えられる．寸法変動を予測し，変動が小さくなるような加工条件を選択できれば，補修工程（決め打ち，切削などの後処理）などの省略に繋げることが期待できる．

## ２．実験方法

### 2.1　プレス機

実験にはアマダ製 SDE8018 のサーボプレス機（図 1 参照）を使用した．（加工後のノックアウトは下テーブルの空気圧を利用することにした．）モーションはパルスモーションを利用した．モーションのパラメータ化に従って，モーションを設定した．



図 1　使用したサーボプレス

### 2.2　モーションのパラメータ化

ニューラルネットワークに適用できるようにモーションをパラメータ化することを検討した．しかしながら，コントロールできる項目をパラメータ化した方が有効であるのは自明であるので，基本的な項目はモーション設定の項目を選択することにした．一方，加工特性に有効そうな項目を選ぶことも重要であるので，その観点で項目を吟味した．パルスモーションを対象にした場合，加工特性に影響を与えそうな項目を表 1 に示す．表中において，それぞれの項目がどのような点で加工特性に影響を与えるかを検討した内容も明記している．

表 1　加工特性への影響要因

| 項目 | 影響する要因 |
|---|---|
| パルス回数 | 変形の回数であるため |
| パルス幅 | 1 回当たりの変形量のため |
| モーション速度 | 変形速度に直結しているため |

加工特性に影響を与える項目の中でも，コントロールが困難で，他のパラメータの影響を受ける従属的な項目もある．そのような項目については，コントロールできる項目で代用できるかを検討した．

例えば，加工時間は加工で発生する加工熱の抜熱に影響する．加工時間が長いとそれだけ金型と接している時間も長いことになり，金型に熱が奪われていく．そのため，加

工時間が加工後寸法に影響を与えると考えられる．しかしながら，加工時間そのものを制御することは非常に困難である．そこで，同じスライド速度でパルスモーションの他パラメータで間接的にコントロールすることにした．（しかし，量産においては，金型の温度変化が寸法変化に大きく影響することが予測される．本研究では，量産を模擬することが難しく，その点に関しての究明ができていない．）使用したアマダのプレス機では，パルスモーション設定で次の項目（追込み量，戻り量，パルス回数）がある．今回はそれらをメインにしてパラメータ化することにした．パルスモーションのモデル図を図 2 に示す．

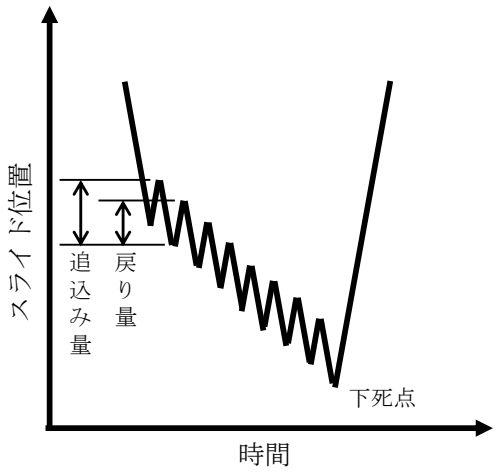



図 2　パルスモーションのモデル図

追込み量は材料を押し込む量であり，変形に関係があると考えられる．戻り量は，追い込みの後に戻る量である．戻り量が大きいと結果として加工時間が長くなる．このパラメータで加工時間はコントロールできる．また，オーバライド率を変えることで加工時間を変えることも可能である．（ただし，オーバライド率による加工時間調整は最終手段とする．）加工時間は材料と金型が接触している時間と同等であると考えている．そのため，繰返し数増加による加工時間の長さも低オーバライド率による加工時間の長さも同等と判断した．

### 2.3　試験片の材質・形状に関して

アルミニウム合金，銅合金，鉄鋼を対象とした加工において，寸法変動を確認した．鉄鋼と銅合金では，寸法変動がアルミニウム合金と比較すると非常に小さく，機械学習に適用するには非常に困難であった．そこで，より寸法変動が大きいアルミニウム合金を使用することにした．また，アルミニウム合金の中でも，A1070 や A2025 など数種類の合金種を検討した．A2025 は加工性が乏しく，加工中に割れてしまったため，使用を見送った．そのほかの合金種は加工可能であったが，結果的に最も変形後の変動が大きかった A1070 材（押出し材）を使用することにした．変形後の差異が分かりやすくなるように，試験片の形状を工夫した [3]．パンチの押込みによる外径の変化の差が出やすいように，試験片とコンテナの間にクリアランスを設けることを検討した．クリアランスが無い試験片の場合，最初から試験片とコンテナが接触してしまい，外径の寸法変動が微小になってしまった．クリアランスを設けることで，ある程度パンチが進むまではコンテナとの接触が抑制されるので，モーションによる寸法変動の差をより顕著にすることができた．コンテナとの間にクリアランスを設けた試験片の形状を図 3 に示す．また，試験後の形状を図 4 に示す．押出し材から切出した後に旋盤で図 3 に示す形状に仕上げた．フランジ部はコンテナ内での位置決めの役割を果たす．コンテナとのクリアランスを 1mm（試験片の外径 30mm），1.5mm（試験片の外径 29mm）で設定した．

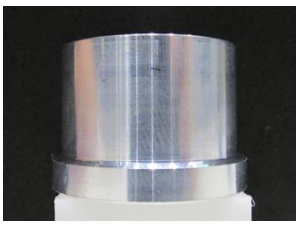


図 3　試験前サンプル

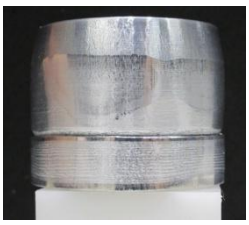


図 4　試験後サンプル

### 2.4　形状計測，および試験片のパラメータ化

形状計測に用いた機器を図 5 に示す，非接触の画像型 3 次元計測機（Micro-Vu：イースタン電子工業株式会社製）である．図 6 に示す試験片を水平方向に設置可能なジグを作製し，その上に試験片を置き，3 次元計測機に鍛造後の底を下側になるように設置した（図 7 参照）．

測定においては，左側の上端を計測の原点と設定した．X 方向を試験片の外径方向とし，Y 方向を試験片の高さ方向とした．原点から外径を計測し，高さ方向に 3mm の間隔で底に向かって外径を計測した．計測の位置関係を図 8 に示す．測定位置は上端から下端に向けて付けた．



図 5　3 次元計測機

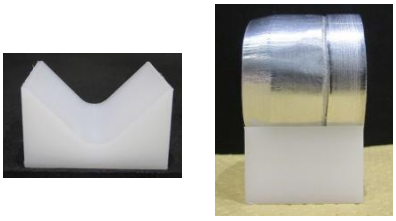


図 6　試験片設置ジグ

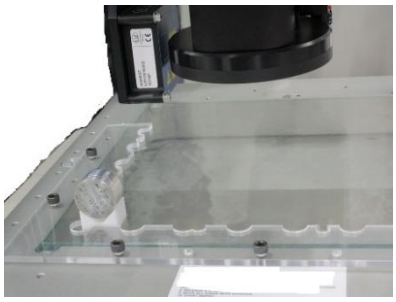


図 7　試験片の設置方法

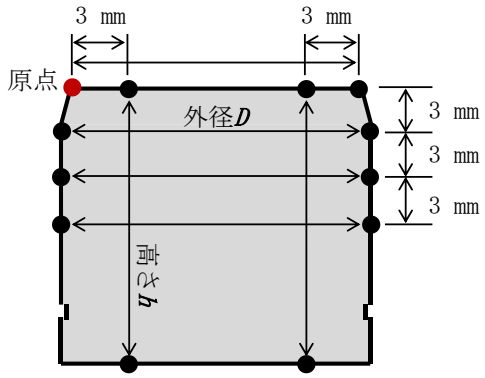



図 8　外径計測位置

鍛造加工前に試験片上端にケガキ線を入れ，そのケガキ線が金型前方に来るように設置し，それを外径の計測時点での目印とした．計測方向はその水平方向とそのケガキ線が鉛直方向になるように設置した方向の 2 方向で計測した．2 方向で計測した値の平均値をその試験片のデータとした．その平均値を学習データとした．

計測方法としては，落射照明で試験片を投影した（図 9 参照）．落射照明で外径を明確にした上で外径に測定点を設定し，2 点間の距離を計測することで外径 ***D*** を計測した（図 8 参照）．

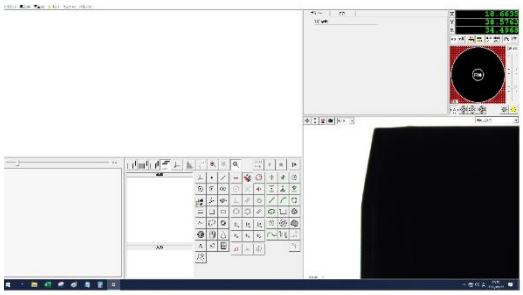


図 9　3 次元計測機操作画面

まず，該当の箇所に測定点を設定し，そのまま X 方向に平行移動していき，反対側の外径にもう一方の測定点を設定する．その後，その 2 点間の距離を計測し，X 方向の変位分が外径 ***D*** になる．外径を計測した後，高さを計測した．高さ ***h*** は両端から 3mm 内側に入った 2 か所と試験片の中央部の 3 箇所で測定した（図 7 参照）．

### 2.5　金型形状

金型は後方押出し加工を対象とし，パンチの寸法は φ18 mm，コンテナの内径は φ32 mm である．加工における減面率は 31.6%になる．ダイハイトを底の厚さが 8 mm になるように調整した．金型（パンチとコンテナ）の材質は高速度工具 SKD11 とした．その他の部分やダイセットは S45C とした．図 10 に金型の写真を示す．



図 10　使用した金型

### 2.6　潤滑油

使用した潤滑油は鉱油をベースとし，その他の添加剤は表 2 に示す．動粘度は 40℃で 247.5 $mm^2/s$ である．試験片の全面に筆で潤滑油を塗布し，コンテナ内に設置した．また，金型のコンテナやパンチにも筆で潤滑油を試験片設置前に塗布した．

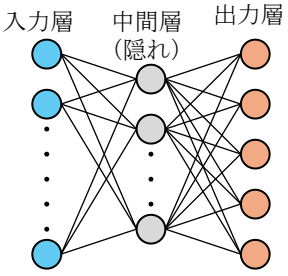
表 2　潤滑油成分

| 主な成分・添加剤 | 成分　wt% |
|---|---|
| 油性剤 | 10～30 |
| 摩耗防止剤 | 25～65 |
| S 系極圧剤 | 10～30 |
| 鉱油 | 15～25 |

## 3. 実験結果，および寸法予測の検証

### 3.1　ニューラルネットワークの概要

前述のように，ニューラルネットワークの方式は順伝播型（多層型，または階層型パーセプトロン）である [4]．入力層と出力層の間に中間層を入れた 3 層構造である．図 11 に概念図を示す．各層に複数のノードを設定し，異なる層のノードとニューロンで連結する．連結したノードに対する影響度で，ニューラルに付加する重み係数を学習していき，寸法変動の予測モデルを構築する．構築したモデルを活用して，内挿がメインの対象となるが，学習データとは異なるモーション条件での寸法予測が可能となる．




$f(p) = q$

図 11　ニューラルネットワーク概念図

### 3.2　モデルの構築

モデル構築のために使用したデータセットの一例を下の表 3，4 に示す．データの傾向として，トップの外径が最も小さく，ボトムに行くにしたがって外径が増加し，最終的にはほぼ一定の値になっていることが確認できる．一定の値はコンテナの内径Φ32mm より少し大きい値である．モーションによる違いとして，パルス回数が増加するほど，トップの外径が大きくなっていることが確認できる．

表 3　学習データの加工条件例

| | | | |
|---|---|---|---|
| 繰返し数 | 2 | 9 | 19 |
| 追込み量 mm | 4.8 | 2.0 | 2.0 |
| 戻り量 mm | 0.3 | 1.0 | 1.5 |

また，試験片の外径が Φ29 mm の結果と，Φ30 mm の結果があり，それぞれの径の結果を別々に学習させたモデルと，両方を同時に学習させたモデルを構築した．

表 4　学習データ例

| 繰返し数 | 2 | 19 |
|---|---|---|
| 測定箇所 1 | 29.8227 | 30.4655 |
| 測定箇所 2 | 32.0988 | 32.2511 |
| 測定箇所 3 | 32.0115 | 32.2540 |
| 測定箇所 4 | 32.1989 | 32.1300 |
| 測定箇所 5 | 32.1515 | 32.3811 |
| 測定箇所 6 | 32.311 | 32.2700 |

### 3.3　寸法の予測

構築した予測モデルを活用して，条件を振って寸法を予測した．予測で変化させたパラメータは追込み量と戻り量である．制御したい量は，追込み量を一定として戻り量との差を変化させた場合と，その差を一定として，追込み量を変化させた場合の 2 ケースで寸法を予測した．追込み量と戻り量の差を 1mm，2mm と固定して，追込み量を 2～7mm で変化させた予測と，追込み量を 3～5mm で固定して，戻り量との差が 0.5mm から 0.5mm 刻みになるように戻り量を設定して予測を実施した．予測結果の一例を図 12，13 に示す．

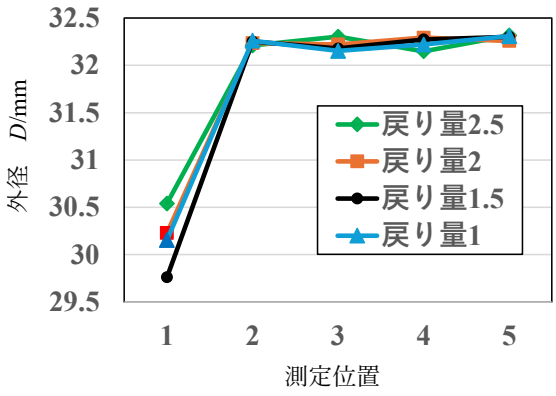



図 12　寸法予測結果（追込み量一定）

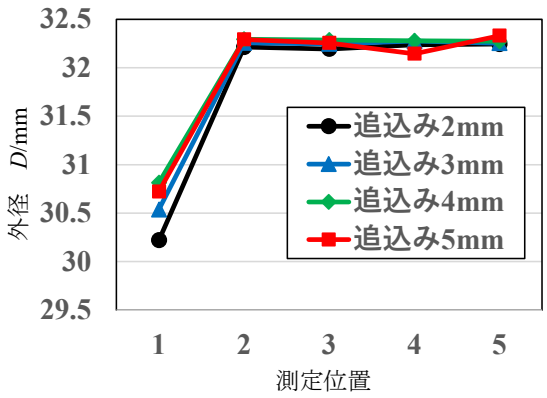



図 13　寸法予測結果（差一定）

示した図は，差を 1 mm に固定した結果と，追込み量を 3mm で固定した結果である．予測した寸法に対して，最も差が大きいのは最上部の外径であった．これはコンテナと接触していないため，モーションによる変形特性の差が大きかったと考えられる．コンテナと接触する位置より下側では，外径の値はほぼ一定となっている．

### 3.4　検証用データセットの取得，検証

モデル構築に使用したデータセットを参考にし，内挿の範囲で検証用データを構築した．予測で使用した加工条件の中で，寸法の差が大きい 2 条件をそれぞれ検証対象とした．追込み量が 3mm 一定とし，戻り量を 1.5mm と 2.5mm の各 2 条件で実際に加工し，加工後の寸法を計測して検証した．差一定についても検証したが，予測と実測との乖離が大きかったので，本報告の対象外とした．予測結果を図 14 に実験後の計測データを図 15 に示す．こちらの結果は実験に使用した外径 Φ29mm に合わせて，Φ29mm の学習データで構築したモデルでの予測結果での比較になる．戻り量が大きい方が，外径が大きくなる傾向を示しており，実験データも同様の傾向を示しているため，定性的な予測は実現できた．ただ，定量的な観点では，予測値と実験値に乖離があり，十分な予測精度ではなかった．

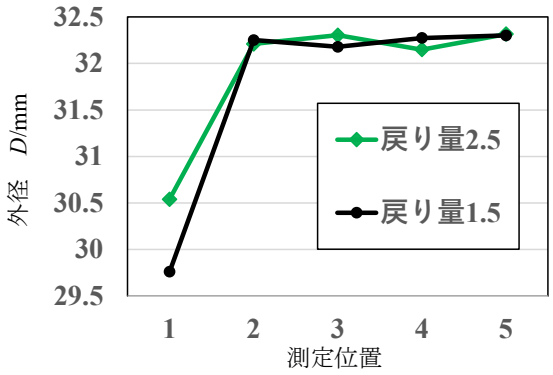



図 14　検証用予測結果

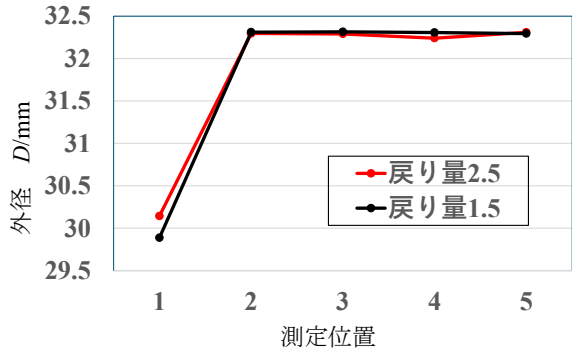
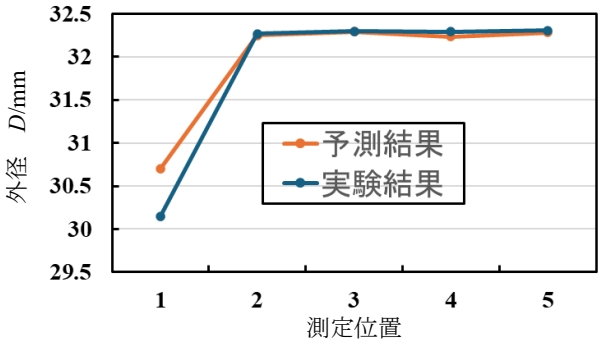
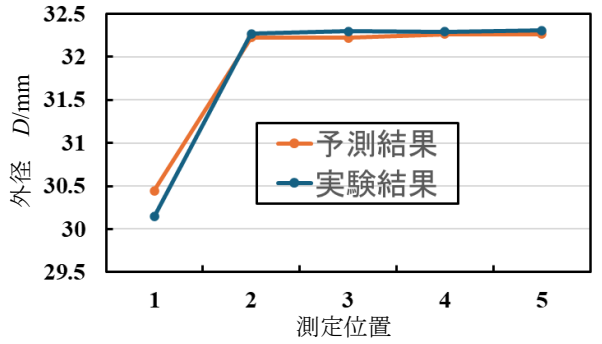



図 15　検証用実験結果

Φ29mm と Φ30mm の学習データで構築したモデルでの予測結果との比較を図 16 に示す．比較しているのは戻り量 2.5mm を対象とした加工条件である．Φ29mm の学習データに比べて，Φ30mm の学習データを加えた方が，実験値との差が縮まっており，より精度よく予測できていることが確認できる．2 種類の試験片外径で構築した場合は，入力条件に外径を追加しており，結果として学習データが増加したため，より精度の良い予測結果になったと考えられる．




(a)　Φ29 のみを学習したモデル




(b)　Φ29 と Φ30 を学習したモデル

図 16　予測モデルによる予測結果の比較

ただし，すべての条件で予測精度が向上せず，予測精度が悪化した実験条件もあった．予測値と実測値の二乗平均平方根誤差 *R*(RMSE)の結果を図 17 に示す．横軸の番号は加工条件を表わしており，詳細については表 5 に示す．この数値は小さいほど予測精度が高いことを示している，図 17 に示すように，繰返し数が 9 から 19 回の間（加工条件 2 と 3 が該当）では，Φ29mm と Φ30mm の学習データで構築したモデルの方において，予測精度が向上している．用意した学習データの内，9 回から 19 回の間は，Φ29ｍｍも Φ30ｍｍも多く含んでいるが，9 回以下は Φ29ｍｍの方が多く，19 回以上は Φ30ｍｍの方が多いと，繰返し数の範囲で偏りが存在した．そのため，9 回から 19 回の範囲の上下限値に近い条件の場合において予測精度が悪化したと考えられる．図に示す条件では，加工条件 1 と 4 が繰返し数において，9 回を下回っており，どちらの予測精度も Φ29 のみのモデルから予測精度の改善が見られなかった，さらに学習データの条件幅を増やすことで改善できると考えられる．

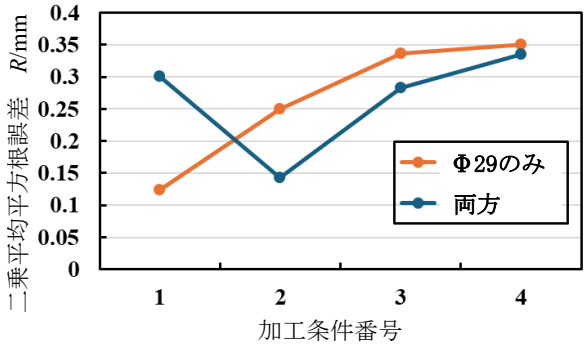



図 17　各加工条件での二乗平均平方根誤差の比較

表 5　加工条件

| 加工条件番号 | 1 | 2 | 3 | 4 |
|---|---|---|---|---|
| 加工時間[s] | 6 | 6 | 6 | 6 |
| 繰返し数 | 6 | 19 | 9 | 8 |
| 追込み量[mm] | 3 | 3 | 2 | 5 |
| 戻り量[mm] | 1.5 | 2.5 | 1 | 4 |

### 3.5　検証結果からのモーション推定，および考察

ダイハイトを変更することによって，途中止めを模した試験を実施し，どの時点で最上部の外径寸法が決定しているのかを確認した．所定の形状までプレスする場合のダイハイトは 344mm であるが，ダイハイトを高く設定することで，パンチの押込みを浅くして，加工の途中止めを模した．ダイハイト 350mm の場合は，試験片の上端傾斜部くらいの深さまでの加工である．ダイハイトの変化と最上部の外径の関係を図 18 に示す．ダイハイトが変化しても，最上端部の外径が変化していないことが確認できる．最上端部の外径をコントロールするのは，その個所をパンチが通り過ぎるまでが重要であることが考えられる．

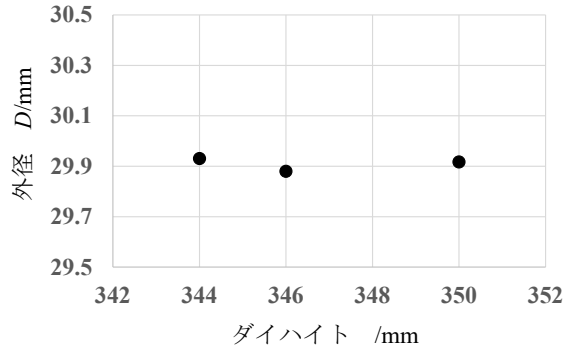


図 18　ダイハイトと最上部外径の関係

予測結果を検討すると，変形初期が緩やかな加工（変形量が少ない条件）において，試験片上端部の外径拡張が大きくなることが考えられる．そこで，加工初期の変形が微小になるようなパルスモーションで実験した．多段パルスモーションを活用し，一段階目のパルスを 0.1mm の押込みで繰返し，深さが 5mm になったら，押込み量を 1mm に増加させて，下死点まで加工する．最上段外径の変化を図 19 に示す．

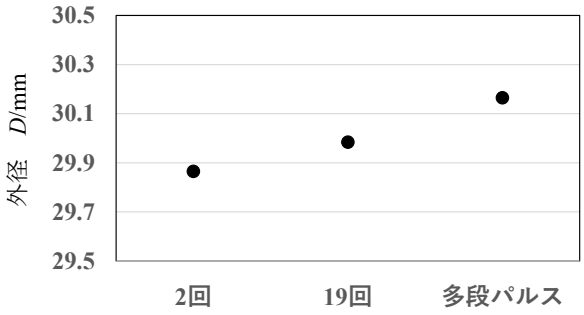


図 19　多段パルスによる最上外径の変化

上端部の寸法が，従来に比べて大きくなっていることが確認できる．このように，寸法予測を検討することで，望むような寸法変化を与えるモーションを設計する指針が得られた．

## ４．おわりに

サーボプレスを用いた後方押出しを対象として，モーションによる寸法変動を，ニューラルネットワークを活用した機械学習で予測するモデルの構築および予測精度を検証した．その結果，定性的な寸法変動予測が可能であり，その予測結果を基に，意図した寸法変動を起こせるモーションの考案に繋がった．今後は，モデルの精度をさらに向上させ，逆問題解析による推奨加工条件提案や，他の形状の加工などに展開していく予定である．

## 謝　辞

本研究の推進に当たり，東海大学の窪田紘明准教授および窪田研究室の川上響君，片倉天兵君，三澤湧輝君，山田亮介君，長谷川玲璃君には，実験の遂行および研究内容の検討において多大な尽力を賜った．ここで篤く御礼申し上げる．また，産業技術総合研究所の荒井裕彦博士には，ニューラルネットワークの予測において，ご助力を賜った．併せて篤く御礼申し上げる．

## 参考文献

1）西村尚：プレス技術，59-11(2021)，18-23.
2）加藤伸明：プレス技術，59-11(2021)，24-28.
3）片倉天兵，三澤湧輝，梶野智史，荒井裕彦，窪田紘明：2025 年度塑加春講演論文集，87-88.
4）吉富康成：ニューラルネットワーク，(2002)，10-15，朝倉書店.