

# 金型内センシング情報を用いた機械学習による成形品の品質予測

Quality Prediction of Molded Products with Machine Learning Using In-mold Sensing Information

大久保勇佐 Y. OKUBO 萩原幸子 S. HAGIHARA 溝口翔太 S. MIZOGUCHI  
馬場紀行 T. BABA 足立智也 T. ADACHI

A method for predicting the quality of plastic products produced by injection molding using sensing data obtained inside molds and machine learning was proposed, and its effectiveness was verified by comparing predicted and experimental results. Technology to modify molding conditions automatically was then developed based on the obtained predicted results.

**Key Words:** quality prediction, machine learning, in-mold sensing information

## 1. はじめに

近年、世界規模での持続可能な開発目標に対する取り組みや ESG 投資の加速に伴い、環境に配慮したモノづくりの重要性が高まっている。特に、自動車業界においては電気自動車や燃料電池自動車などの開発に加え、燃費向上を目的とした自動車部品の軽量化が行われており、金属部品を樹脂化する流れが加速している。

一般的な樹脂部品の射出成形工程においては、外的要因によって熔融樹脂粘度が変動して成形結果が変化する。このため、オペレーターが必要に応じて成形条件を調整することで品質を保持しており、品質はその熟練度に影響を受けている。そのため、熟練度に依存しない品質安定化の観点から、成形機自体の知能化に関する研究が進められている。たとえば、塩入らは、射出成形工程において、成形条件などの情報とニューラルネットワークを用いて品質を予測する技術を構築している<sup>1)</sup>。また、成形品質は金型内における樹脂流動挙動などに強く依存することが知られているが<sup>2)</sup>、成形対象により金型形状は多種多様なため樹脂流動挙動も一意に定まらず、汎用的な知見を得るのは困難である。このため、金型内の情報を使用した品質予測に関する研究例は少ないのが現状である。

本報では、射出成形品の一例として、当社の重要製品の一つである玉軸受の樹脂保持器（図 1）の質量と内径寸法を対象に、金型内センシング情報を含めた成形過程における各情報と機械学習を用いた成形品の品質予測手法を構築する。また、質量および内径寸法の予測結果と

実測結果を比較することで、手法の有効性を検証する。さらに品質安定化を目的に、予測結果を用いた成形条件の自動調整を試みる。なお、樹脂成形では、成形品の内部に空気が残留することでボイドと呼ばれる現象が発生する場合があります。機能部品においては強度低下や破壊の原因となる可能性がある。このボイドの発生有無を正確に把握するには、X 線 CT 法が有効であるが、その測定には長時間を要するため、成形品の全数を測定することは現実的ではない。したがって本研究では、成形品の質量をボイド管理のための代替品質指標と定めた。また、内径寸法は要求寸法許容差を管理するための品質指標である。




図 1 玉軸受の構成部品  
Ball bearing components

## 2. 品質予測手法の検討

### 2.1 金型内センシング情報の必要性

従来の研究<sup>2)</sup>より、成形品質は金型内の樹脂流動挙動に強く依存することが知られている。そのため、成形時の金型内における樹脂状態の情報を活用することで、高精度に品質予測ができるようになる。

## 2.2 機械学習の活用

成形過程において溶融された樹脂は、PVT 特性に代表される非線形挙動を有することが知られている。PVT 特性とは、樹脂の温度や付与される圧力によって、樹脂の比容積（単位：cm<sup>3</sup>/g）が変化する特性である。さらに、成形過程の樹脂は、短時間で溶融状態から固化状態に変化するため、温度や粘度も急激に変化していると推測される。この点を勘案して、品質予測には、非線形性を考慮可能な機械学習手法の活用が有効と考える。

高精度な品質予測を実現するため、金型内センシング情報と非線形性を考慮可能な機械学習手法を用いた品質予測手法を検討する。

## 3. 機械学習

### 3.1 手法の選定

質量や内径寸法の予測には、連続値の予測が必要となり、機械学習では回帰問題に分類される。表1に回帰分析に適用可能な代表的な機械学習手法を示す。回帰分析手法は、線形回帰法と非線形回帰法に大別され、各手法は異なる特徴があるため、目的に応じた手法の選定が必要である。たとえば、ニューラルネットワークのような大量データを必要とするアプローチを用いた場合、製造業などの試作段階では、学習データ数の少なさゆえに、精度不足を招く可能性がある。そこで本検討では、2.2節で述べたように非線形性を考慮可能であること、また比較的少量の学習データ数で高い予測精度が期待できる<sup>3)</sup>ことの2点を理由に Support Vector Regression (以下、SVR) を採用した。

表1 代表的な回帰分析手法  
Typical regression analysis methods

	Method Name	Characteristic
Linear Methods	Simple Regression	Easier interpretation of result
	Multiple Regression	Easier interpretation of result
	Ridge Regression	Prevent overfitting
Non-linear Methods	Support Vector Regression	High accuracy with relatively few data
	Random Forest	High accuracy with relatively few data
	Neural Network	Very high accuracy with much data

### 3.2 SVRの概要

SVRは、カーネル法を用いることで非線形性を考慮したモデリングを実現する。カーネル法とは、学習データに含まれる特徴ベクトルを高次元に非線形変換し、その非線形空間で線形モデリングする手法である。SVRでは、式(1)を最小化するように学習される。

$$E(w) = \frac{1}{2} \|w\|^2 + C \sum_i |y_i - f(x_i)|_\epsilon \quad (1)$$

ただし、

$$|y_i - f(x_i)|_\epsilon = \max(0, |y_i - f(x_i)| - \epsilon) \quad (2)$$

である。ここで  $y_i$  と  $x_i$  は学習に用いられる  $i$  番目のデータ、 $w$  は重みベクトル、 $\epsilon$  は誤差のしきい値、 $C$  は二つの項の間で重みづけを調整するための係数である。式(1)を最小化することにより、学習データへの適用性と汎化性能のバランスのとれた非線形モデルが得られる。カーネル法に用いるカーネル関数には、式(3)に示すガウシアンカーネルを使用する。

$$K(x, x') = e^{-\gamma \|x - x'\|^2} \quad (3)$$

なお  $\epsilon$ 、 $C$  および  $\gamma$  は学習データの特徴に応じて最適化が必要な係数であり、本検討ではグリッドサーチと呼ばれる手法を用いて決定した。グリッドサーチは、各係数を規則的かつ網羅的に少しずつ動かしながら計算し、計算した中で最も精度の高い組み合わせを選択する方法である。この手法は直感的に理解しやすいことから、機械学習コミュニティにおいて広く利用されている<sup>4)</sup>。

## 4. 試験方法

### 4.1 成形データの収集

成形機はSR100H（住友重機械工業製）を、樹脂材料にはガラス繊維で強化したポリアミド材を使用し、射出成形にて試験を行う。ここでは、成形中の金型内の樹脂状態を把握するため、圧力センサーおよび赤外線検出式温度センサーを金型内に設置し、圧力と温度を実測する。金型内に設置したセンサーのレイアウトを図2に、設置した圧力センサーで実測した結果の一例を図3に示す。成形機の射出開始をトリガーとして計測を開始し、ウェルド部、ゲート部、ランナー部、ノズル部における充填、保圧、冷却工程の圧力履歴を取得している。また、成形

品の品質データは、電子天びんおよび形状測定機を用いて、質量と内径寸法を測定している。




図2 金型内のセンサーレイアウト  
Sensor layout




図3 金型内圧力センサーの実測結果  
Sensing data inside the mold

### 4.2 特徴量およびデータセットの作成

一般的に、機械学習の学習データとして時系列データを取り扱う場合、学習モデルの精度や学習効率の向上を目的として、データの特徴的な部分を抽出し、特徴量として指定する。本検討では、金型内に設置したセンサーで取得した圧力と温度履歴を対象に、最大値や特定領域の積分値など、120種類の特徴量を作成した。さらにこれらの特徴量をそれぞれの品質データとひも付けることで、学習用のデータセットとして集約した(表2)。

表2 学習用データセット  
Dataset

Molding conditions	Qualities		Features							
	Quality 1	Quality 2	1	2	3	4	5	6	7	8
91.66933	342.02	342.77	342.51	342.4	354.35	354.91	355.01	354.68		
91.74032	341.83	342.18	341.99	341.7	353.73	354.22	354.36	354.06		
91.76106	340.81	341.4	341.48	341.4	353.1	353.5	353.75	353.44		
91.79343	340.38	340.74	340.92	340.45	352.3	352.66	353.02	352.68		
91.81947	339.9	340.54	340.79	340.11	351.55	351.88	352.25	351.95		
91.18731	332.48	332.74	332.7	332.7	348.25	348.43	348.97	348.97		
91.39011	335.6	336.2	336.2	336.2	349.32	349.32	349.32	349.32		
91.61446	338.71	339.87	339.87	339.87	351.82	352.05	352.69	352.69		
91.80657	342.06	342.86	342.86	342.86	354.42	354.58	354.3	354.3		
92.0532	345.32	346.69	346.69	346.69	356.45	356.68	357.37	356.97		
91.85865	340.81	341.4	341.48	341.4	353.1	353.5	353.75	353.44		
91.82864	340.81	341.4	341.48	341.4	353.1	353.5	353.75	353.44		
...	...	...	...	...	...	...	...	...		

### 4.3 重要特徴量の選択

SVRのような回帰分析に用いられる機械学習手法では、学習に用いる説明変数が少数であるほど過学習を起こしにくい<sup>5)</sup>。過学習とは、統計や機械学習の分野において、学習時に利用したデータにのみ過剰に適合してしまうために、未知のデータに対する適合性が低下し、予測精度が著しく低下する現象である。したがって、過学習を避けるには、成形理論や経験に基づく知見・知識から最適な説明変数を選択することが望ましい。しかしながら、樹脂成形のように複雑な現象を取り扱う場合、すべての樹脂流動挙動を理解したうえで、適切な変数を選択することは容易でない。

そこで本検討では、この問題に対し、データ駆動による解決を考える。具体的には、品質データを目的変数に、4.2節で作成した数多くの特徴量を説明変数とし、統計的手法を用いて重要な特徴量の自動選択を試みる。なお、それぞれのデータは正規化処理し、特徴量間の重みを等価に扱う。

統計的手法を用いた特徴量の自動選択には、回帰モデル系<sup>6)</sup>やグラフィカルモデル系<sup>7)</sup>など、数多くのアルゴリズムが提案されているが、どの場合にどのアルゴリズムが適しているか判断指標がなく、経験的に選ぶことが多い。しかしながら、各アルゴリズムは対象となるデータによって適性があり、実装したアルゴリズムが必ずしも妥当な解を導くわけではない点に注意が必要である。この課題を解決するため、本報では複数のアルゴリズムを併用したロジックを考案する。図4に特徴量選択に用いる処理の概要を表3に使用した4種類のアルゴリズムを示す。各アルゴリズムの特徴は以下のとおりである。

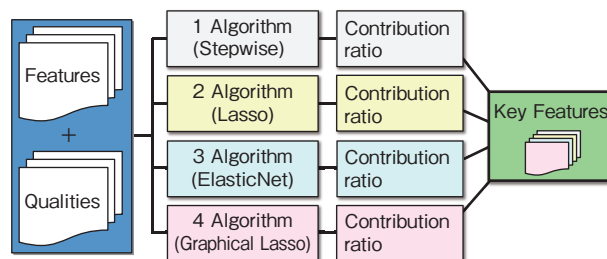


図4 特徴量選択手法の概要  
Process for feature selection

表3 特徴量選択のアルゴリズム  
Statistical method algorithms

Algorithm	Loss function
Stepwise	$\operatorname{argmin} \epsilon(w) = \sum (y - Xw)^2$
Lasso	$\operatorname{argmin} \epsilon(w) = \sum (y - Xw)^2 + \lambda \sum  w $
ElasticNet	$\operatorname{argmin} \epsilon(w) = \sum (y - Xw)^2 + \lambda \sum \{ \alpha  w  + (1 - \alpha) w^2 \}$
Graphical Lasso	$\operatorname{argmax}_A \{ \ln \det A - \operatorname{Tr}(SA) - \rho \ A\ _1 \}$

① Stepwise<sup>5)</sup>

学習モデルに一つずつ説明変数を追加したり、削除したりしながら、最適な説明変数の組み合わせを探索する回帰手法である。この手法は、説明変数同士で相関の強い組が存在する場合、学習モデルの推定が不安定になるデメリットもある。

② Lasso<sup>6)</sup>

回帰モデルに L1 正則化項を加えた手法である。正則化により、前述した Stepwise のデメリットを回避することができる。また、L1 正則化はスパースな解を導く性質を持ち、この性質が変数の自動選択を可能にする。ただし、説明変数同士で相関の強い変数群が存在する場合、その中から一つの変数しか選択できないデメリットがある。

③ ElasticNet<sup>9)</sup>

正則化項に L1 ノルムと L2 ノルムの和を用いる点が特徴である。説明変数同士で相関の強い変数群をグルーピングする効果があるため、Lasso のデメリットを回避できる。

④ Graphical Lasso<sup>7)</sup>

ガウシアングラフィカルモデルにスパース性を導入した手法である。①～③の手法とはアプローチが異なり、疑似相関を排除して、変数間の相関関係を明らかにする特徴を有する。

図4の処理にしたがい、4種類のアプローチで品質に対する各特徴量の寄与度を算出した後、それぞれの算出結果を統合することで、SVRに入力する特徴量を自動で選択する。

## 5. 品質予測結果および考察

ここでは、これまでに述べた金型内センシング情報と非線形性を考慮可能な機械学習手法を用いた品質予測手法の妥当性を検証するために、質量と内径寸法の予測結果と実測結果から算出される決定係数を比較する。また、品質安定化を目的に、予測結果に基づいた成形条件の自動調整を試みる。

### 5.1 金型内センシング情報の有無による予測結果比較

金型内センシング情報の有無による質量と内径寸法の予測結果を図5に示す。図5から金型内センシング情報を取り入れることにより、質量と内径寸法の決定係数は各々0.86から0.9に、0.8から0.93に向上していることが分かる。これは、2.1節で述べた仮説のとおり、成形条件設定値が実際の樹脂流動挙動とかけ離れ、金型内に取り付けたセンサーから得た情報が実際の現象に近いと推測される。




図5 金型内センシング情報の有無による予測結果の比較  
Comparison of the determination coefficients with and without sensing information

### 5.2 機械学習の有無による予測結果比較

次に、金型内センシング情報に対して、機械学習の非線形回帰法 SVR を用いた場合と古典的な線形回帰法の重回帰分析を用いた場合での質量と内径寸法の予測結果を図6に示す。図6から、機械学習の非線形回帰法 SVR の活用により、質量と内径寸法の決定係数は各々0.91から0.98に、0.8から0.93に向上したことが分かる。これは、樹脂の PVT 特性や冷却過程の非線形性を近似できたためと推測される。これら樹脂の非線形性に関するメカニズムをすべて解明することはきわめて困難であることから2.2節で述べた仮説のとおり、非線形性を考慮した機械学習手法の適用は有効であると考えられる。

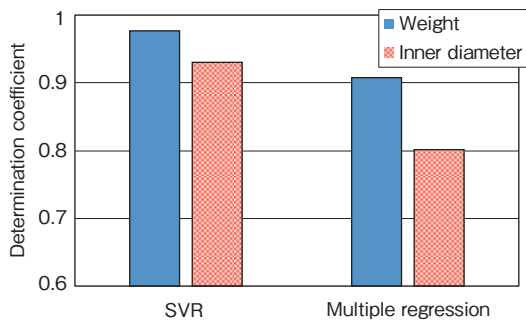


図6 機械学習の有無による予測結果の比較

Comparison of the determination coefficients between SVR and multiple regression

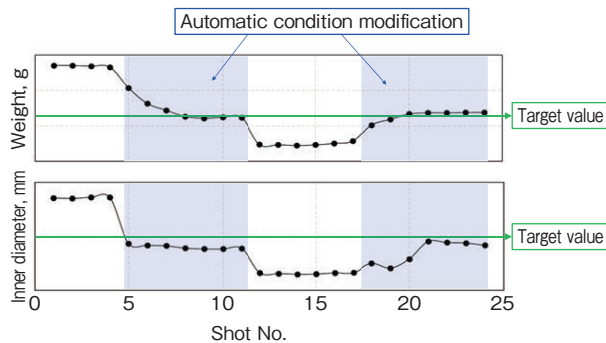


図8 質量と内径寸法の実測結果履歴

Measured results of weight and inner diameter under automatic molding

### 5.3 成形条件の自動調整

ここでは、品質安定化を目的に、本報で検討した品質予測手法を用いた成形条件の自動調整について述べる。質量と内径寸法の予測値と目標値の差に基づいて、実測結果が目標値に近づくよう成形条件を自動調整するシステムの概要を図7に示す。まず、成形ごとに取得される圧力・温度履歴を特徴量に変換し、計算用サーバーへ送信する。サーバー側は特徴量を受信すると、学習済モデルで品質を予測し、目標値との差に基づいて成形条件の修正量を算出した後、成形機の設定値を自動で調整する。本システムを用いて成形条件を自動調整した場合の質量、内径寸法の実測結果の履歴を図8に示す。なお、本システムの性能を確認するため、自動調整を行う前に、それぞれの品質値を目標値から強制的にかい離させている。図より、成形条件の自動調整で、質量、内径寸法共に目標値へ収束することが分かる。したがって、検討した品質予測手法の成形条件の自動調整に対する適用可能性が示された。

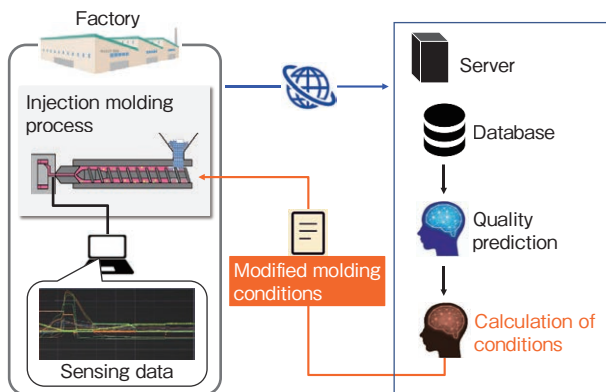


図7 成形条件自動調整システムの概要

Architecture for automatic modification of molding conditions

## 6. おわりに

本報では、軸受樹脂保持器の質量と内径寸法を対象に金型内センシング情報と機械学習を用いた成形品の品質予測手法を構築した。金型内センシング情報を機械学習モデルの学習に取り入れるることにより、質量と内径寸法の予測結果と実測結果の一致性を表す決定係数は各々0.86から0.98に、0.8から0.93に向上した。また、機械学習の非線形回帰法SVRの活用により、古典的な線形回帰法に比べて質量と内径寸法の決定係数が各々0.91から0.98に、0.8から0.93に向上した。さらに、本手法を用いて成形条件の自動調整を試みた結果、その適用可能性が示唆された。

## 参考文献


- 1) 塩入隆仁, 山極佳年, 岩下英紀: 射出成形機から見た成形品質予測手法, プラスチック成形加工学会誌, Vol. 18, No. 8 (2006) p-p. 579-582.
- 2) 横井秀俊, 増田範通, 小崎龍一: 射出成形金型面に作用するせん断応力分布計測, 生産研究, 46巻, 12号 (1994) p-p. 75-78.
- 3) Charalampos Bratsas, Kleonthis Koupidis, Josep-Maria Salanova, Konstantinos Giannakopoulos, Aristeidis Kaloudis, Georgia Aifadopoulou: A Comparison of Machine Learning Methods for the Prediction of Traffic Speed in Urban Places, Sustainability, 12, 142 (2020).
- 4) 尾崎嘉彦, 野村将寛, 大西正輝: 機械学習におけるハイパーパラメータ最適化手法: 概要と特徴, 電子情報通信学会論文誌, Vol. J103-D, No. 9 (2020) pp. 615-631.
- 5) 鈴木大慈: 過学習と正則化, 応用数理, 28巻, 2号 (2018) pp. 28-33.

- 6) 廣瀬 慧：スパースモデリングとモデル選択，電子情報通信学会論文誌，Vol. 99, No. 5 (2016) pp. 392-399.
- 7) 島村徹平，井元清哉，山口 類，宮野 悟：L1 正則化法に基づくグラフィカルガウシアンモデリングについて，人工知能学会第二種研究会資料，2007 巻，DMSM-A701 号 (2007) pp. 1-4.
- 8) 谷 宏，早川誠而，堀口郁夫：NOAA データと地理データによる気温推定に関する研究，山口大学農学部学術報告，41 号 (1993) pp. 25-35.
- 9) Zou H, Hastie T: Regularization and variable selection via the elastic net, J. Roy. Statist. Soc. Ser. B, 67 (2005) pp. 301-320.

筆 者



大久保勇佐\*  
Y. OKUBO



萩原幸子\*  
S. HAGIHARA



溝口翔太\*  
S. MIZOGUCHI



馬場紀行\*\*  
T. BABA



足立智也\*\*  
T. ADACHI

\* 研究開発本部 データアナリティクス研究部  
\*\* 研究開発本部 材料研究部