

研究論文

長繊維 CF RTP の射出成形条件のデータ駆動型最適化

杉本貴紀^{*1}、渡邊竜也^{*2}、吉田陽子^{*1}、柴田佳孝^{*3}、足立吉隆^{*4}

Data-Driven Optimization for Injection Conditions of Long Fiber CF RTP

Takanori SUGIMOTO^{*1}, Tatsuya WATANABE^{*2}, Yoko YOSHIDA^{*1}, Yoshitaka SHIBATA^{*3}, and Yoshitaka ADACHI^{*4}Technical Support Department^{*1*3} Mikawa Textile Research Center^{*2} Nagoya University^{*4}

本研究では、炭素繊維強化熱可塑性樹脂の射出成形条件の最適化において、機械学習を用いたデータ駆動型最適化の手法を適用した。入力変数には成形条件、出力変数には成形品重量・引張強度とした教師データを学習させたニューラルネットワークモデルを用いて、成形品の重量と引張強度をともに大きくする成形条件を複数予測した。それらの条件で実際に成形・測定して、教師データでは得られなかった重量と引張強度の組み合わせを実証した。

1. はじめに

工業部材に用いられる樹脂成形品の性能は、材料だけでなく、成形条件の影響も大きく受ける。そのため、要求性能を満たす最適な成形条件を見出すことが重要であるが、熟練技術者の経験と勘に頼るところが大きい。また、要求性能の項目が多いほど、最適化が難しくなる。このようなことは、樹脂成形品に限らず、工業部材一般に言えることであり、多くの中小企業では、技術者の育成と経験・ノウハウの継承、さらなる技術力の強化が常日頃の課題である。これらの解決に役立つ一つの手法として、データを活用したプロセスインフォマティクスが挙げられ、射出成形の分野でも、いくつかの取り組みがある^{1)~4)}。具体的には、入力変数(=製造条件)と出力変数(=部材の性能値)の実験データを用意し、それらを関連付けた回帰式(=機械学習モデル)を PC 上で構築することによって、ノウハウの可視化や性能向上が見込める製造条件の予測に活用できることが報告されている。

本研究では、データと機械学習を用いたプロセスインフォマティクスの一例として、射出成形条件の最適化を検討した。具体的には、繊維長が長い長繊維の炭素繊維強化熱可塑性樹脂(CFRTP)成形品の、重量と引張強度をともに最大化する成形条件の予測と実証を行った。

2. 実験方法

2.1 教師データ

材料には、長繊維 CF 強化 6 ナイロンペレット(東レ(株)製 TLP1060、CF 含有量 30wt%)、射出成形機には

東洋機械金属(株)製 Si-15V を用いた。成形品は、JIS K 7139 タイプ A13 に準拠したダンベル形の縮尺試験片(平行部長さ 24mm, 平行部の幅 3.5mm, 厚さ 2.0mm)とした。ここでは、可塑化条件(回転速度、背圧、可塑化位置)を固定とし、射出条件、保圧冷却条件として表 1 の範囲から経験的に選定した 93 の組み合わせ条件にて成形した。なお、シリンダー温度は、シリンダー先端からホッパー直下までを 4 分割して設定可能であるが、ここでは、すべて同一の値とした。また、入力変数 X3 で用いる 1 次圧は直接設定できる値ではないため、あらかじめシリンダー温度、射出速度、V-P 切替位置の組み合わせ毎に予備試験を行って成形機から取得し、その値を元に保圧の値を設定した。

1 条件当たり 3 個の成形品について、ゲートカット後のダンベル試験片重量(以下重量)と引張強度を測定し、出力変数とした。引張試験については、試験片を 100℃・6 時間の予備乾燥ののち、室温 23℃にて、精密万能試験機((株)島津製作所製 AG-50kNXplus)を用い

表 1 データの項目と範囲

入力変数(成形条件)	教師データ範囲	予測データ範囲
X1 シリンダー温度(℃)	250~280	260~280
X2 金型温度(℃)	40~100	40~100
X3 保圧/1次圧@V-P 切替位置	0.38~1.1 (成形時の実測値から算出)	0.3~1.0
X4 保圧時間(sec)	3~10	2~10
X5 射出速度(mm/sec)	30~200	20~200
X6 V-P切替位置(mm)	3~6	3~6
出力変数		
Y1 重量(g)	成形条件毎に実験から取得 (n = 3 [1成形条件あたり])	機械学習モデルから算出
Y2 引張強度(MPa)		

^{*1} 技術支援部 計測分析室 ^{*2} 三河繊維技術センター 産業資材開発室 ^{*3} 技術支援部 計測分析室(現産業科学技術課) ^{*4} 名古屋大学

て、クロスヘッド速度 2mm/min で行った。

2.2 機械学習モデルのハイパーパラメータチューニング

機械学習モデルには、ニューラルネットワークを用いた。簡便のために、2 種の出力変数を 1 モデルで扱い、中間層を 1 層・活性化関数は \tanh に固定した。中間層のユニット数と荷重減衰の値をモデルのハイパーパラメータとし、10-fold cross validation(seed 値固定)によるベイズ最適化にて決定した。

3. 実験結果及び考察

3.1 教師データ

入力変数の頻度を図 1 に示す。本研究では、93 の成形条件の組み合わせを経験的に選定したため、条件選択に偏りが生じた。機械学習による回帰モデルを構築する場合において、教師データの分布の状態が、適切なモデル構築の可否に影響を及ぼすことがある。そのため、実験計画法など、教師データ取得のための的確な条件設定手法を取り入れることが今後の課題である。これらの手法を取り入れることができれば、93 よりも少ない成形条件の教師データで、以降に示したモデル構築結果と同等の結果を得られる可能性がある。

入力変数と出力変数の散布図と、両者の相関係数を図 2、図 3 に示す。重量については、シリンダー温度、金型温度、保圧/1 次圧、保圧時間との間にある程度の相関が認められた。シリンダー温度、保圧時間については、一様な右肩上がりではなく、傾向が複雑であった。一方、引張強度については、いずれの入力変数とも明確な相関がみられなかった。入力変数同士が互いに独立で出力変数に対してそれぞれ線形の関係、という前提では表現できないような、非常に複雑な関係があるものと推測された。

3.2 機械学習モデル評価

ニューラルネットワークモデル構築結果を図 4 に示す。横軸は教師データの出力変数の実験値、縦軸は、教師デ

ータの入力変数の値をモデルに代入して計算させた、出力変数の推定値であり、いずれも正規化した無次元の値である。出力変数の実験値と推定値が完全に一致した場合を図の対角線で示した。パイパーパラメータチューニングを行ったモデルについて、教師データを 9:1 で訓練データ(train)とテストデータ(test)に分け、モデル性能を評価した。具体的には、訓練データとテストデータの二乗平均平方根誤差(RMSE_train, RMSE_test)について、重量(Y1)、引張強度(Y2)のそれぞれで図中に示した。いずれも、RMSE_train と RMSE_test がほぼ同じ値となったことから、学習不足や過学習ではない、適切なモデルが構築できたと考えられる。このモデルのユニット数は 30、荷重減衰の値は 0.001 であった。

重量のモデルと引張強度のモデルを比較すると、引張強度の RMSE(_train, _test)の値が、重量の値に比べて大きかった。この要因として、①前述した教師データの入力変数の偏りが引張強度データの学習において不利であったこと、②教師データの入力変数の種類が引張強度を表現するには相対的に不十分であったこと、③ニューラルネットワークモデルを中間層 1 層に限定したために、重量に比べて複雑であろうと想定される入力変数と引張強度の関係を表現できなかったこと、④他の機械学習モデルの可能性を未検討であること、などが考えられる。特に②について、CFRTP の物性には繊維配向の影響があることは広く知られていることから、成形品の繊維配向の指標を入力変数に加えることによって、モデル精度の向上が期待される。しかし、繊維配向のような、新たな測定・解析をわざわざ実施しなければ得られない指標を機械学習モデルに不可欠な入力変数にすることは、現場での機械学習の使いやすさを阻害するものと考えられる。一方で、本研究で取り上げた入力変数は射出成形機の設定条件あるいは成形機から容易にモニタリングできる値であり、製造現場で値を入手しやすい入力変数を用いた機械学習モデルは実際に活用しやすいといえる。




図 1 入力変数の分布

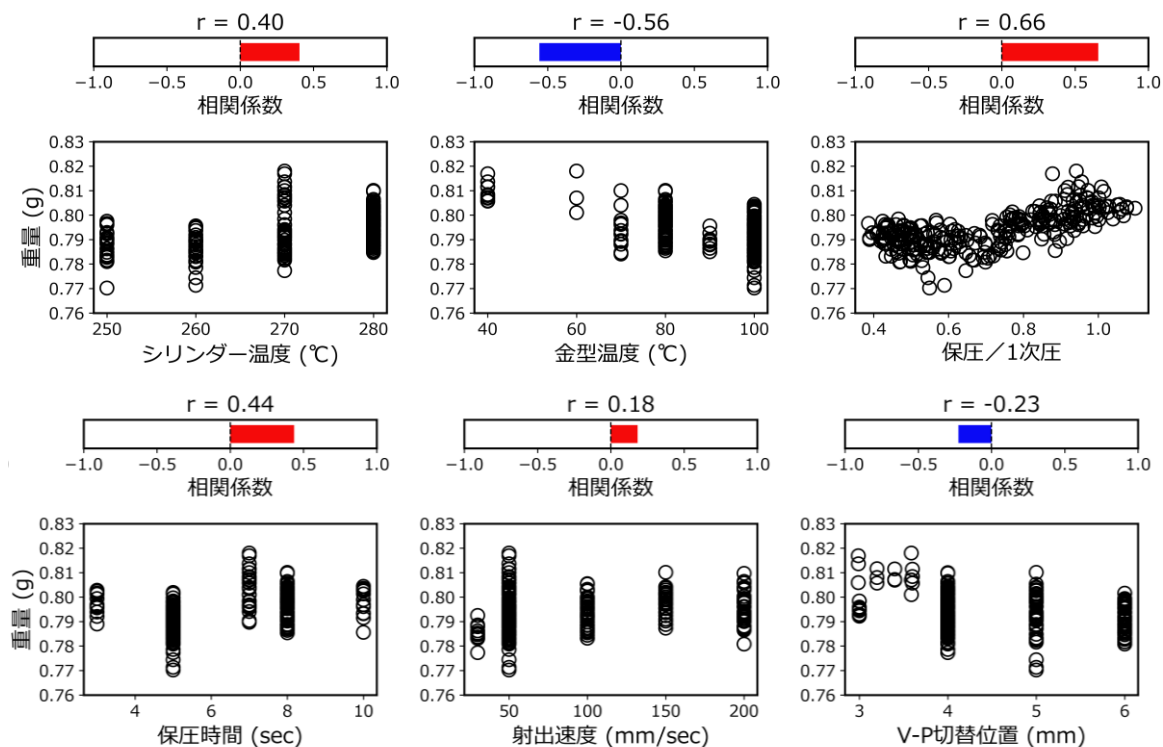


図2 入力変数と重量の散布図

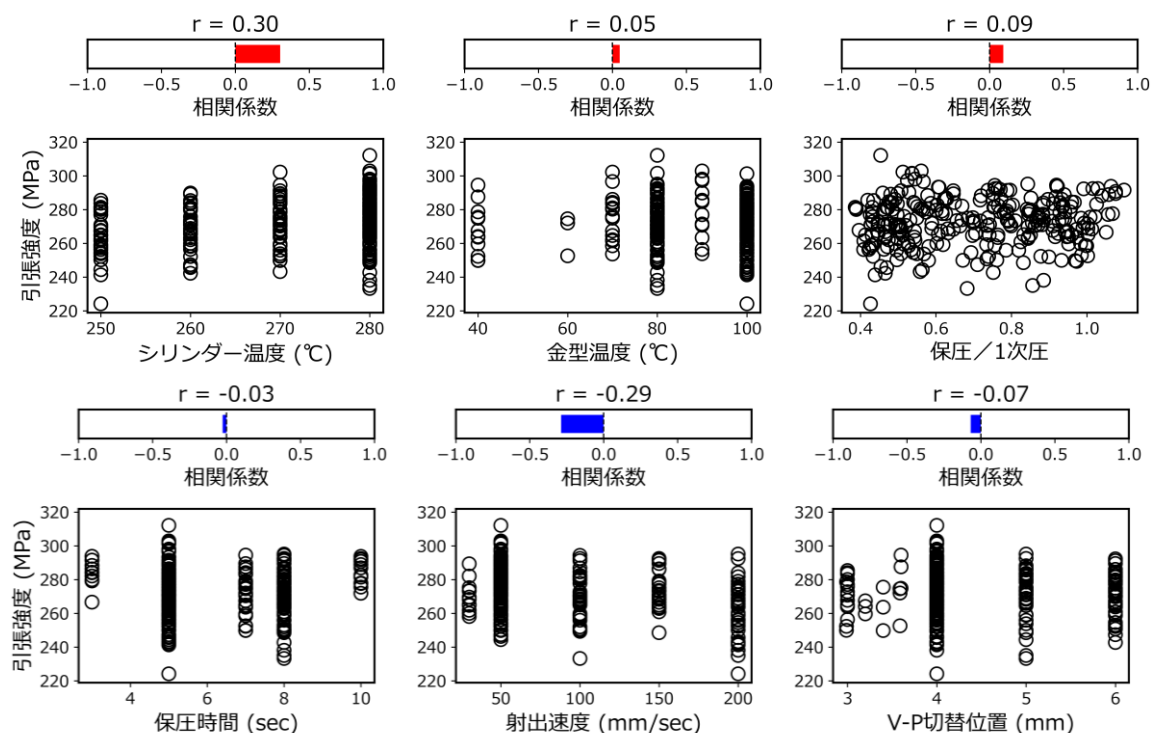


図3 入力変数と引張強度の散布図

教師データの準備の難易度とモデル精度のバランスについては、機械学習モデルの活用目的に照らし合わせて個々に検討する必要がある。

3.3 成形条件の最適化

重量(Y1)、引張強度(Y2)それぞれについて、3種のseed値でハイパーパラメータチューニングしたモデル

を用いて、表1に示す成形条件の予測データ範囲の総当たり組み合わせで予測値を算出した。金型実測によるダンベル試験片寸法と樹脂の密度から算出した計算上の最大充填重量は0.813gであることから、その99~100%の範囲の重量の予測値データに絞った。さらに引張強度の予測値を降順に並べて上位の成形条件、つまり、重量




図 4 構築したモデルの評価

が最大となる付近で、引張強度をさらに大きくできると予測される成形条件を複数抽出した(表 2)。これらの成形条件からモデルが予測する値は、重量(Y1)が 0.804g、引張強度(Y2)が 291-293MPa であった。

これらの成形条件で実際に成形し、重量と引張強度を実測・検証した(図 5)。予測成形条件で得たデータ(●)のプロット横の数字は、表 2 の成形条件番号に対応している。ニューラルネットワークモデルが予測した成形条件では、重量が最大となる付近で、教師データに比べて引張強度が大きくなり、機械学習モデルにより重量と引張強度をともに最大化する成形条件を予測できたことを実証した。

表 2 モデルが予測した成形条件

入力変数(予測した成形条件)	①	②	③	④	⑤	⑥	⑦
X1 シリンダー温度(°C)	280	280	280	280	280	280	280
X2 金型温度(°C)	40	40	40	40	60	60	80
X3 保圧/1次圧@V-P切替位置	0.95	0.95	0.95	0.95	0.7	0.8	0.95
X4 保圧時間(sec)	5	5	5	5	4	2	2
X5 射出速度(mm/sec)	40	40	20	20	20	20	20
X6 V-P切替位置(mm)	4	3	5	4	3	3.5	3




図 5 予測成形条件における実証結果

4. 結び

長繊維 CFRTP の射出成形において、重量と引張強度をともに最大化する条件を、機械学習の回帰モデルにより予測した。結果は以下のとおりである。

- (1) ニューラルネットワークモデルを構築し、予測した成形条件で、重量と引張強度をともに大きくできることを実証した。
- (2) 教師データの取得方法や入力変数の取捨選択、ニューラルネットワークモデルの構造に改善の可能性があることが分かった。

謝辞

本研究における引張試験の実施に当たっては、産業技術センターの高橋様にご協力頂きました。

付記

本研究は、愛知県と公益財団法人科学技術交流財団が実施する「知の拠点あいち重点研究プロジェクト IV 期」(PD3:MI をローカルに活用した生産プロセスのデジタル革新)において実施した。

文献

- 1) 高田新吾, 山地俊則, 鈴木徹, 竹林良浩, 小野巧, 依田智: 科学と工業, **96**, 321(2022)
- 2) 足立智也, 馬場紀行, 木村幸治, 大久保勇佐, 黒川貴則: 成形加工, **35**(2), 57(2023)
- 3) 岡宏樹, 内山祐介: 成形加工, **35**(2), 60(2023)
- 4) 杉本貴紀, 渡邊竜也, 吉田陽子, 柴田佳孝, 足立吉隆: 成形加工, **36**(9), 371(2024)