

1. 委託事業名： AIによるプラスチック射出成形不良の原因分析と発生予測

2. 委託事業者名： 委託団体：愛工業株式会社

連携大学：静岡理工科大学情報学部 特任教授 富樫 敦

3. 研究成果概要：

【背景】

◇製造業と不良ロス

不良品発生による損失は、どのような製造工法においても共通の課題であり、不良の早期発見と未然防止は目指すべき共通の目標である。

生産状況をリアルタイムに取得し、不良品の予測や発見するには、数多くのセンサーと監視体制が必要となる。しかし、小規模な製造事業者では監視を行う技能士の確保、状態を監視するためのセンサーとシステム費用、システム管理を行うIoT技術者の確保等の課題があり、一般的な仕組みとして広がっていない。また金型等の製造工具が社外資産である場合もあり、製造事業者のみで構築できる仕組みが必要である。




図1. データ化、見える化による早期発見・早期対応のイメージ

【目的】

本事業の目的は、蓄積したビッグデータとリアルタイムデータを用いて不良発生を予測するシステムを構築する事、そしてAIを活用する事による不良ロス最小化である。またその中でベテランの経験と勘に頼った不良の分析を補填する手法についても探る。

【研究結果および成果】

◇愛工業データの分析とビッグデータ生成

愛工業のプラスチック成形製造現場データを表1に示す。AIによるデータ解析及び学習を行うためには、個々のデータが関連付けされたビッグデータを作成する必要がある。

表 1. 製造現場のデータ一覧

データ	主な内容	更新頻度
電子日報	製品、不良情報	データ更新都度
成形機情報	操作情報	操作毎
成形ショット	成形	生産サイクル毎
環境情報	工場温・湿度	1min 毎
	水温・流量	1min 毎

時間間隔が最も短い成形ショット情報を基盤とし、製品データと不良データを電子日報より、設備操作情報を成形機情報より、温湿度等の環境情報を環境データより抽出。検証データとして 2024 年 6 月 1 日～2024 年 10 月 30 日の 6 ヶ月分、300 万行のデータを生成。その内 60% を訓練データ、20%を検証データ、20%をテストデータとし、解析を行った。

なお、データ分析とビッグデータ生成は共同研究先の静岡理工科大学の協力にて実施した。

◇新規データの取得

プラスチック射出成形の三大要素として、材料、成形機、金型が挙げられる。愛工業では成形機の情報を取得できており、今回のデータ分析に活用している。材料特性をタイムリーに取得する事は現実的ではないため、実施しない。金型内の状況を把握するには圧力センサーや温度センサーを金型内に設置する必要があるが、多品種の生産を行う生産体系の場合は、多数の金型改造やセンサー及びシステム費、管理工数の増大が課題となる。

今回の事業では金型を通して戻った温調水を設備側で計測し（図 3）、間接的に金型の状態を観測する事に取組み、コストと管理工数を最小限にする事を狙う。取得したデータはビッグデータに統合する事で、不良分析の更なる深堀に活用する。




図 2. 金型周辺のデータ取得

◇原因分析と不良予測モデルの選定

原因分析と不良予測モデルは共同研究先である静岡理工科大学の協力にて実施した。

モデルとしては Auto Regressive Moving Average (以後、ARMA)、決定木、ランダムフォレスト、One class SVM、リッジ回帰、Neural Network (以降 NN)、オートエンコーダ(以降 AE)を検討した。

◇評価指標の検討

モデルの性能評価には二値分類機械学習モデルの性能を測る指標として用いられる混合行列を使用した。混合行列の値より正解率(Accuracy) や適合率(Precision)、再現率(Recall) を求める事ができる。二値とは良品であるか不良品であるかの 2 クラスの事である。今回の評価指標では、正解率とは良品と不良品が正しく予測された率、適合率は不良品と予測したデータが実際の不良品と適合しているかの率、再現率は実際の不良品が予測で不良品として再現されているかの率の事。また今回は F スコアも評価指標として利用した。これら評価指標は値が 1 に近づくほど、機械学習モデルの性能が高いと評価できる。

◇モデルの評価

生成したビッグデータにて各種モデルにて訓練、検証、テストを実施し、評価を行った。ランダムフォレスト、OneclassSVM、Isolation Forest は正解率以外の指標が 0 となっていることから、不良予測に失敗していることが確認できる。リッジ回帰や決定木、NN については適合率が極度に低いため、少数クラスである不良のデータを過度に予測していると考察できる。しかし、リッジ回帰と NN の再現度は高くなっているため、ハイパーパラメータの調整や閾値の最適化によりモデルの性能向上が期待される。

表 2. モデル評価

モデル名	正解率	適合率	再現率	F 値
決定木	0.83	0.0004	0.23	0.008
ランダムフォレスト	0.99	0	0	0
OneclassSVM	0.99	0	0	0
Isolation Forest	0.99	0	0	0
リッジ回帰	0.71	0.0003	0.29	0.0005
Neural Network	0.41	0.0006	0.63	0.001

機械学習モデルとしては改善が必要な結果だったが、元データにおける不良率が極めて低いことが原因と考えられる。不良でないデータが過剰に学習され、その結果過学習が発生した可能性が高い。

◇実データの確認

特定のデータにてショート不良の特徴パラメータを抽出し (図 4)、その傾向を確認した。ショート不良発生に寄与したパラメータは背圧と確認できたが、モデル予測では重要度が第 3 位と低く、不良予測を行うためにはモデルの精度向上が必要。

表3. 抽出された特徴パラメータとその重要度

特徴パラメータ	重要度	不良発生に寄与
射出時間 [s]	0.06	×
H1 温度 [°C]	0.048	×
背圧 [MPa]	0.047	○

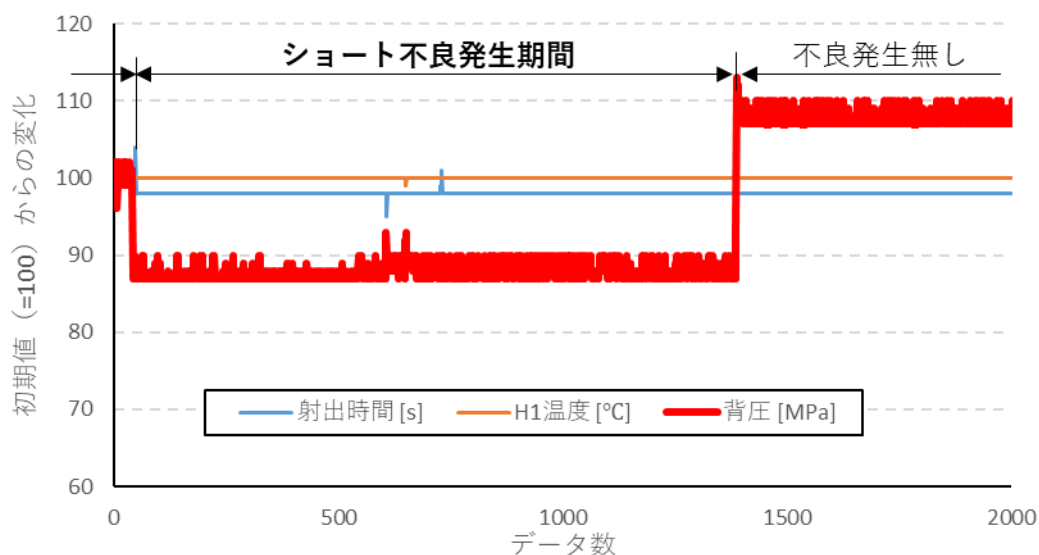


図3. 実データでの現象確認

【まとめ】

本事業では、不良発生を予測するシステムの基盤を構築するため、新規データ取得、ビッグデータ生成、不良予測のためのモデル検討と評価を行った。

モデル評価の結果、リッジ回帰、決定木、NN は過剰に不良データを予測しており、適合率が低い一方で再現率が高いことが分かった。これらのモデルではハイパーパラメータの調整や閾値の最適化が必要であり、今後性能向上が期待される。しかし、元データにおける不良率が極めて低かったことで、不良でないデータが過剰に学習され、モデル精度に悪影響を与えた可能性がある。今後はデータバランスの改善や、ハイパーパラメータ調整、閾値最適化を通じて、不良予測の精度向上を行う。

【地域社会への波及効果】

今回の事業で取り組んだビッグデータやモデルは特定の製造工程に特化しておらず、一般化された仕組み作りが狙い。仕組みが成熟すれば将来的には、他の製造工程においても良品と不良品を説明できるデータを取得する事で、同じように不良予測を行うモデルを構築する事ができるようになる。その結果、製造業を担う地域の中小企業の不良ロスを削減し、経営状態を改善、地域社会の発展に波及する事が可能となる。