

機械学習手法を活用したウレタンハンドルの不良低減

東條陽介^{*1}Utilizing Machine Learning to Reduce Failures
in Urethane Steering WheelsYosuke Tojo^{*1}

要旨

ウレタンハンドルの高品質化・低コスト化を進めるために、材料開発と生産技術開発に取り組んでいる。その成果として不良率は減少してきているが、近年では下げ止まり傾向となっている。この理由は特定できていない不良要因が残存しているためであると考えられる。

そこで、従来からの変化点として機械学習手法を活用し、ウレタンハンドルのネック不良対策に取り組んだ。その結果、新たな不良要因を特定し、不良低減を実現できたのでその内容を報告する。

Abstract

Development of material and production technology has led to higher quality and lower costs in urethane steering wheels. This resulted in a decreasing failure rate, but in recent years that decrease has leveled out. The reason is that there are still some defect factors that have yet to be specified.

As a new approach, we utilized machine learning methods in working to develop measures to prevent neck failure. As a result, we were able to identify a new failure factor and further reduce the number of failures.

1. はじめに

私たちは生活をする上で大量の資源を使い、大量の二酸化炭素を排出し続けている。このような活動が、地球環境に大きな負担をかけている。

豊田合成は樹脂やゴムの専門メーカーとして次世代に繋がる持続可能な発展のために、つくるだけでなく廃棄まで責任を持って二酸化炭素排出量ゼロや廃棄物ゼロを目指す責任がある。

その活動として、設備の蒸気/エアレス化、コンパクト化、統合などによる省エネの追求、リサイクルによる廃棄物低減、ビッグデータを活用した不良ゼロ活動などを行っている。

今回は、その中で機械学習手法を活用したウレタンハンドルの不良低減について報告する。

2. 背景

ウレタンハンドルは、車両の進行方向を制御する機能を有しており、耐久性、外観品質、触感品質が求められる製品である。そのため、長年に渡って高品質化、低コスト化を目指した材料開発と

生産技術開発に取り組んでいる。

製品は、型内成形によって芯金の周りにポリウレタンを形作る構成である（図-1）。また製造工程としては、材料を配合して設備に投入し、ウレタン成形した後に仕上げ検査が行われる（図-2）。

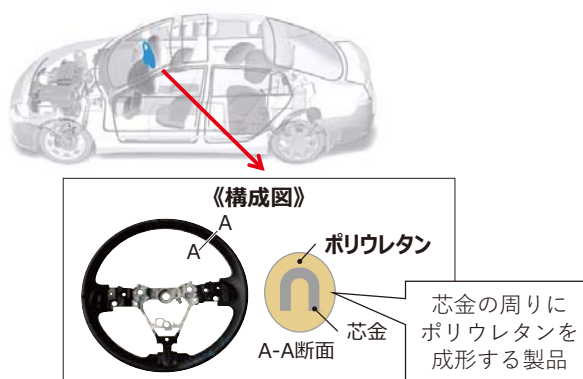


図-1 ウレタンハンドルの概要



図-2 製造工程の概要

*1 生産技術統括部 IoT 推進室

3. 問題の明確化

ウレタンハンドルの不良率は、長年の製造現場における不良低減活動によって減少傾向となっている。その一方で、近年では不良率が下げ止まりとなっている。このような状況の中で、これまでと同様のスキル・経験に基づいた不良低減活動に加え、新たな取り組みが必要だと考えられる。

実際に製造工程で使用している代表的なウレタン材料の不良率を比較すると従来材に比べて開発材の不良率が高い（図-3）。従来知見を反映している場合、本来であれば開発材も従来材と同等レベルの不良率であるべきだと考えられる。このことから「開発材の不良率が高い」ことが問題であると考えた。

更に開発材の不良の発生状況を確認すると、外観不良（図-4）が多いことが確認できた。また、このような外観不良の他材料での発生状況を確認すると、開発材での発生が多いことも分かった。

以上のことから、問題点は「開発材特有のネック不良として外観不良があること」と考えた。




図-3 材料別の不良率比較




図-4 外観不良の様子

4. 目標設定

本テーマでは、一連の取り組みによる効果を最大にするため、開発材の外観不良低減及び、新たな不良要因を見出すことを狙って、不良対策の取り組みに機械学習手法を活用し、真因追究を実施した。併せて、必要な情報をデータ化するための環境構築も行った。

5. 要因解析

5-1. データ収集環境構築

対象工程は、原材料の配合作業及び、配合材料の設備への投入を人作業によって行っている。また、既設の設備であるため、データの収集・蓄積が考慮されていない設備である。そのため、配合結果と成形条件と成形結果を紐付けする必要がある。

あった。

そこで、原材料の配合結果と配合時間及び、材料の設備への投入時間についてはデータロガーを用いてデータ化を行った。また、成形条件については、成形設備のPLCに各種センサ情報を集約して1成形ごとのデータを蓄積した。この波形データを用いてVBAによって特徴量を計算し、1成形ごとの特徴量のデータ化を行った。以上の取り組みによって、ウレタン成形工程のデータ収集環境を構築した（図-5）。




図-5 ウレタン成形工程データ化の概要

5-2. 工程データの紐付け

工程のデータを全て活用するためには、配合から検査までのデータを紐付けする必要がある。ウレタン成形工程においては、各工程の時間関係に着目して紐付けを行った（図-6）。

配合時間	投入時間
2020/7/1 9:00	2020/7/1 10:00
紐付け	
2020/7/2 13:05	2020/7/2 13:35
紐付け	

着眼点① 配合時間と投入時間の関係
配合と投入は必ず交互に作業実施
⇒ 配合直後の投入時間と紐付け
(a) 配合時間と投入時間の紐付け

投入時間	成形時間
2020/7/1 10:00	2020/7/1 9:58
紐付け	2020/7/1 10:03
	...
2020/7/2 13:35	2020/7/2 13:30
紐付け	2020/7/2 13:40

着眼点② 投入時間と成形時間の関係
投入直後の成形から配合の影響を受ける
⇒ 投入時間の以降の成形時間と紐付け
(b) 投入時間と成形時間の紐付け

成形時間	検査時間
2020/7/1 9:58	2020/7/1 10:02
紐付け	
2020/7/1 10:03	
2020/7/1 10:08	2020/7/1 10:12
紐付け	

着眼点③ 成形時間と検査時間の関係
成形した後すぐに検査実施
⇒ 検査直前の成形時間と紐付け
(c) 成形時間と検査時間の紐付け

図-6 データ紐付けの考え方

5-3. 特徴量計算

収集したデータを解析するために、蓄積した波形データを良品と不良に分類し、波形の差を可視化した(図-7)。手順としては、検査結果を基にして良品波形と不良波形に分類し、それぞれ重ね合わせて描画する。これにより、良品と不良のそれぞれでのばらつきが分かる。更に両方を重ねることで良品と不良の差(=特徴)が生じるポイントが分かる。

以上を踏まえて、特徴が出る点における成形条件の値から特徴量を計算し、成形データを用意した。更に、材料重量を示す配合データと、不良の有無(0:良品, 1:不良)を示す検査データを紐付けることで、解析に必要な配合データ、成形データ、検査データが揃ったデータマトリックスを作成した。




図-7 特徴量の考え方

5-4. 不均衡データの是正

解析に使用したデータは殆どが良品データであり、不良データは数%以下のレベルである。このようにデータサイズに偏りがある場合、不良の情報量が少ないために解析精度が低くなる。仮に全てを良品と判定する解析モデルであっても予測精度が高いという結果になる恐れがある。このような状況では不良を良品と予測することになるため、意味のある結果が得られない可能性が大きい。

このような不均衡データへの対策として、Synthetic Minority Over-sampling Technique (SMOTE)¹⁾に着目した(図-8)。




図-8 SMOTE 処理の概要

SMOTEは少数データの増加(オーバーサンプリング)と多数データの減少(アンダーサンプリング)を併せて実施する手法である。少数データに対しては、データの分布を維持しながら

近傍データを合成する。一方で、多数データについても同様にデータの分布を維持しながらデータを削減し、データ量の不均衡を是正する。

そこで、検査データの0,1をラベルとしたSMOTE処理を行った。元データに対してSMOTE処理を行うことで、不良データを生成し、解析用データ(SMOTE後データ)とした(図-9)。結果として不良データ量を10倍程度まで増加させることができた。このとき、それぞれのデータの分布を確認すると、SMOTE後データは元データと似た分布になっていることから(図-10)、SMOTEによって生成したデータは、元データと同じ特性を保持しながら不良データの情報量が増加したことが分かる。




図-9 SMOTEによる不良データ増加

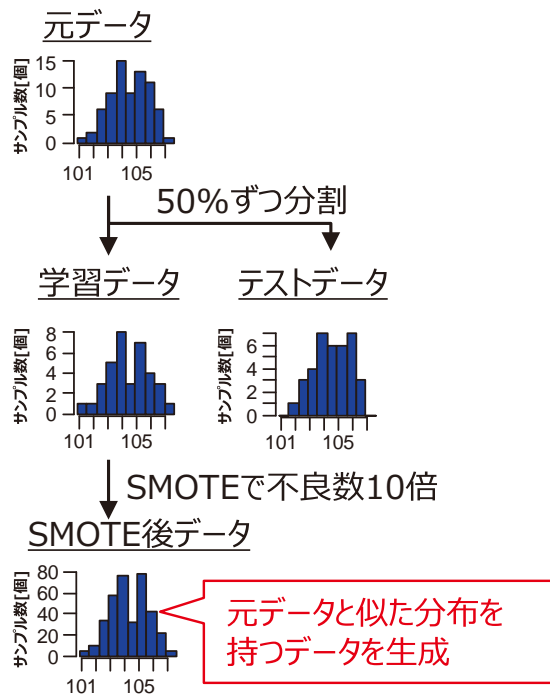


図-10 SMOTE後のデータ分布例

5-5. 解析方針

目的変数は不良の有無(0:良品, 1:不良)とする。また、説明変数と目的変数の関係性が不明であるため、解析には線形モデルと非線形モデルの両者を試みる。説明変数間に多重共線性がある

ことも懸念点であるため、多重共線性がある場合でも解析可能な手法を用いる必要があると考えた。

以上の条件より、線形モデルの解析手法として正則化回帰、非線形モデルの解析手法としてランダムフォレストの2手法によって不良の要因解析を進めた。

5-6. 不良要因の絞り込み

正則化回帰の解析結果を図-11に、ランダムフォレストの解析結果を図-12に示す。このとき、両方の手法で影響度が高い因子として配合に関係する因子が抽出された。また、上位2因子が共通しており、今回は最も影響度が大きいと判定された配合因子Aに着目した。




図-11 正則化回帰結果




図-12 ランダムフォレスト結果

5-7. 解析結果の検証

続いて、配合因子Aの影響を検証するために、配合因子Aの条件を変化させたときの外観不良の不良率との関係性を散布図によって確認した(図-13)。その結果、配合因子Aが小さい程外観不良の不良率が減少する傾向が確認できた。これは正則化回帰の結果と一致している。

配合因子Aの役割には、材料の反応を促進するものがある。そのため、本来であればウレタンが型に追従してから硬化するが、配合因子Aが大きい場合ではウレタンが型の形状に追従する前に硬化してしまうことで、外観不良が発生すると考えられる(図-14)。




図-13 外観不良の不良率と配合因子Aの関係

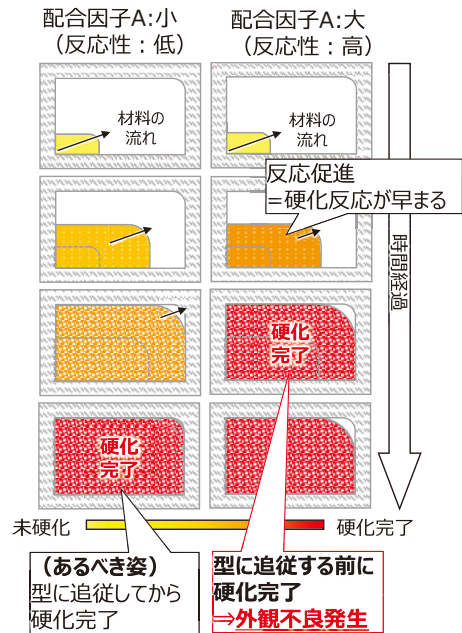


図-14 外観不良への配合因子Aの影響

6. 対策立案

解析結果及び検証結果を踏まえて、配合因子Aの上限値を下げる対策を提案する。上限値を下げるにあたっての懸念事項としては、実際の工程能力から実現可能な設定にできているかという点がある。そこで現状の条件幅(〇〇~□□)での配合実績から工程能力を確認したところ、バラツキ幅としては××%であることが確認できた(図-15)。これは、提案する条件幅(〇〇~△△)以下であることから、作業として実現可能な条件幅であることが確認できたので、配合因子Aの条件を変更した。




図-15 配合因子Aの条件提案

7. 効果確認

配合因子 A の条件変更前後での外観不良率の推移を図-16 に示す。対策を実施したタイミングでの不良率が低減していることが確認できた。また、対策前後の期間でそれぞれ不良率を算出した結果、外観不良が 51% 低減し、不良率を半減させることができた。




図-16 対策前後の外観不良率推移

8. まとめ、おわりに

機械学習手法を活用することで、新たな不良要因を抽出することができ、不良対策に寄与することができた。今回の取り組みで抽出した因子については、製造・生技を交えて条件設定・管理の見直しを進める。

一方で解析精度向上は大きな課題である。この課題を解決するためには、解析技術の向上と、設備の状態や設備内の材料物性をリアルタイムで把握できるようなセンシング技術の向上が必要になってくると考える。今後も世の中の技術動向を把握しながら継続して検討していく。

参考文献

- 1) 本橋智光：前処理大全 [データ分析のための SQL/R/Python 実践テクニック], 技術評論社, 2018, p.146

著 者



東條陽介