

# AIを活用した良品条件探索と変化点検知の自動化

## Automation of Good Condition Search and Change Point Detection by Utilizing AI

末高 直樹<sup>\*1</sup> 柴田 顕次<sup>\*1</sup> 寺田 侑司<sup>\*1</sup> 鈴木 祐輔<sup>\*2</sup>  
 Naoki Suetaka Kenji Shibata Yuji Terada Yusuke Suzuki

\*1 ITデジタル推進部 \*2 コンプレッサ事業部 アルミ技術部

### 要 旨

全社DX推進活動の一環として、2020年度にダイカスト工程を対象にビッグデータ分析を行い、良品率が高い生産条件の特定とその条件による生産を監視するシステムの開発を実施し、データを活用した働き方の効果を検証した。その結果、良品率が向上し、効果が確認できたため、他工場・他工程への適応を検討したが、適応毎に分析作業が必要となる課題を抱えていた。そこで今回、AIの技術を活用して自動で良品率が高い条件を探索するモデルを開発することで適応工数を削減し、展開性を向上させた。

キーワード：DX、AI、Autoencoder、K-means++、品質管理

### Abstract

As part of the company-wide DX promotion activities, a big data analysis was conducted for the die casting process in FY2020 to identify production conditions with a high percentage of good products and to develop a system to monitor production under those conditions to verify the effectiveness of data-based work methods. As a result, the good product rate was improved and the effectiveness of the system was confirmed, so the company considered adapting the system to other plants and processes, but the system had the problem of requiring analysis work for each adaptation. This time, we developed a model that automatically searches for conditions that have a high good product rate by using AI technology, thereby reducing the man-hours required for adaptation and improving the deployability.

Keywords: DX, AI, Autoencoder, K-means++, Quality control

## 1 はじめに

近年、様々な業種・企業においてDX(デジタルトランスフォーメーション)が重要視されている。DXとは、経済産業省の「DX推進ガイドライン」において、「企業がビジネス環境の激しい変化に対応し、データとデジタル技術を活用して、顧客や社会のニーズを基に、製品やサービス、ビジネスモデルを変革するとともに、業務そのものや、組織、プロセス、企業文化・風土を変革し、競争上の優位性を確立すること」と定義されている<sup>[1]</sup>。この定義の通り、DXの推進が不十分な企業は競争力を失い、ビジネスそのものが成り立たなくなる危険性をはらんでいる。それは当社のようなものづくりの会社においても決して例外ではない。

このような背景から、当部では、全社DXを推進すべく、安全なITデジタル環境の提供や全社デジタル化を支える最適ナリソースの確保を行った。働き方変革と機能強化を目指し、モデルラインでデジタル技術活用の実証を行い、成果を全社に広める活動に取り組んでいる。

## 2 2020年度の実証内容と課題

### 2.1 モデルラインの選定

全社DX推進活動の一環として、2020年度にダイカスト工程をモデルラインとした取り組みを行った。ダイカスト工程をモデルラインとした理由は2つある。1つ目は、ダイカストは品質への影響要因が多く、計測・制御が難しいため、トヨタグループ内でも現場におけるデータ活用が進んでいないからである。2つ目は、ダイカスト工程ではデータを活用した働き方に効果が期待できるからである。図1に示すように、ダイカストの不良の多くを占める鋳巣は鋳造時には検出できず、後工程の加工工程で表面に露出し、目視検査工程で不良判定が行われている。不良が多発した際には、不良ロットの回収を行い、熟練作業者が原因の調査とダイカスト工程への対策を実施している。そのため、データ変動を予測し、不良が多発する前に対策可能な環境を構築することにより、不良率低減や早期の対策着手などの効果が期待できる。

以上より、ダイカスト工程をモデルラインとし、図1に示すデータを活用した働き方の効果を確認するための実証を行った。




図1 ダイカスト工程における改善の流れ  
Fig.1 Flow of improvement in Die Casting process

## 2.2 実証内容と課題

本実証では、はじめに対象のダイカストマシンのデータ収集環境を構築した。要因系統図を作成し、品質に影響を与える要因の洗い出しを行い、センサーを付けて1ショット(1回の生産)あたり数十種類の時系列データ(数万点)を収集する環境を構築した。この環境を用いて、2年以上のデータを収集し、数十万ショットのデータを確保した。次に、各種時系列データを手作業で分析し、品質への影響やばらつきがある箇所を図2のとおり特徴量と定義した。その後、作成した数百種類の特徴量と不良率の相関を確認し、各特徴量において不良率が低い条件を見つけ出した。

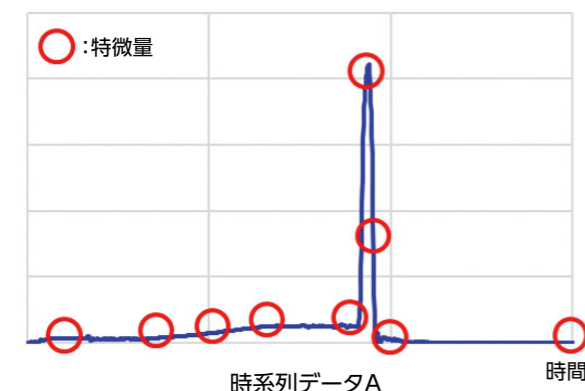


図2 特徴量定義  
Fig.2 Definition of features

最後に、不良率が低い条件で生産できるように、工程の改善とその条件で生産できているかを監視するシステムの開発を行った。その結果、目標不良率を達成し、良品率の向上と維持に貢献することができたため、データを活用した働き方の効果を確認できた。

さらなる効果創出をねらい、実証内容を他工場へ展開することを検討したが、展開するためにはデータ分析を行い、監視システムを展開先のデータに適応させる必要がある。しかし、これらのデー

タ分析は手作業で行っており、適応には膨大な工数がかかるため、他工場への展開に向けて適応工数を削減する必要がある。

## 3 開発のねらい

本開発では、監視システムの適応工数削減による展開性向上のため、AIの技術を活用し、人の分析作業を自動化することを目指す。今回取り組んだ内容は、図3に示すとおり、自動で良品条件(不良率が低いデータ群)を探索するモデルと良品条件からの変化を検知する変化点検知モデルの開発、変化点検知モデルを活用した監視ルールの定義である。

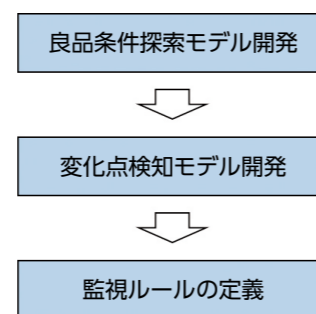


図3 開発の流れ  
Fig.3 Development flow

## 4 良品条件探索モデルの開発

クラスタリングの技術を活用し、自動で良品条件を探索する良品条件探索モデルを開発した。クラスタリングとは機械学習手法の一種で、図4のようにデータ間の類似度が高いデータをグルーピングする手法であり、クラスタリングで作成したグループをクラスタと呼ぶ。今回はクラスタリングにより、類似度が高いショットデータをグルーピングした後、各クラスタの不良率の調査を行い、良品条件を見つけ出す。なお、今回は不良率を30%低減することを目指したため、不良率を30%以上低減可能なクラスタを良品条件とする。




図4 クラスタリングのイメージ  
Fig.4 Image of clustering

## 4.1 データ前処理

クラスタリングをするため、分析対象データの前処理を行った。機械学習に使用するデータに欠損や異常値が含まれている場合、分析の精度に悪影響を及ぼすため、データ前処理が必要である。まず、図5に示すように、各種時系列データの可視化結果を目視で確認し、ダイカストマシンの動作として異常なデータや外れ値を除去した。その後、同一ショットのデータを結合し、クラスタリングに使用するデータセット\*を作成した。

\*データセットとは、分析対象のデータ群のことを示す。




図5 時系列データの異常値除去  
Fig.5 Outlier removal for time series data

## 4.2 クラスタ数の決定方法の検討

クラスタリングを行う際に、事前にグルーピングするクラスタ数を決定する必要があり、一般的には、各クラスタ内のデータの類似度を最大化するようにクラスタ数を定義する。例として、図4のデータをクラスタリングする場合には、青枠と赤枠の中にデータの塊が存在するため、クラスタ数を2と定義する。しかし、このようにデータ間の類似度を最大化する方法では、品質情報をもとにクラスタ数を決定していないため、不良率を30%以上低減可能な良品条件を必ず見つけ出すことができるとは限らない。

そこで、クラスタ数の決定方法を工夫し、必ず良品条件を見つげ出すことができる方法を確立した。今回実施したクラスタ数決定の流れは次の①～③である(図6)。

- ① 全データの不良率を調査
- ② 2つのクラスタにグルーピングし、各クラスタの不良率を調査
- ③ 各クラスタの低減不良率を算出し、低減不良率の最大値が目標値を超えている場合は終了し、超えていない場合はクラスタ数を1つ増やし、再度②以降を実施

このように、目標を満たすクラスタを作成できるまで、クラスタ数を増やしていく方法を考えた。また、目標を満たすクラスタを作成できた際には、そのクラスタを良品条件と定義した。

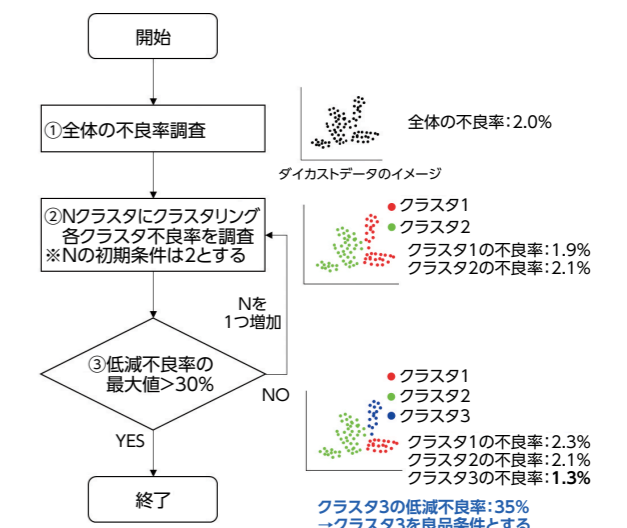


図6 クラスタ数決定の流れ  
Fig.6 Flow of determining the number of clusters

## 4.3 アルゴリズムの選定とモデルの開発

類似度が高いデータを高速にグルーピングし、良品条件を見つげ出すことを目標としたため、機械学習手法であるK-means++を採用した。K-means++とは、データ間の距離を用いてクラスタリングする手法であり、次の①～⑤の流れで実施する(図7)。

- ① クラスタ数を設定
- ② クラスタ数分のクラスタ中心点をランダムで作成(各クラスタ中心点は離れるように作成する)
- ③ データとクラスタ中心点の距離を求め、各データを最も距離が近い中心点のクラスタに分類する
- ④ 各クラスタのデータの重心を求め、重心をクラスタ中心点に置き換える
- ⑤ ④の結果、中心点に変化がない場合は終了し、変化がある場合は再度③以降を実施

K-means++は、このようにクラスタ中心点の更新と全データの分類を繰り返すことで、距離が近いデータをグルーピングする手法となっている。

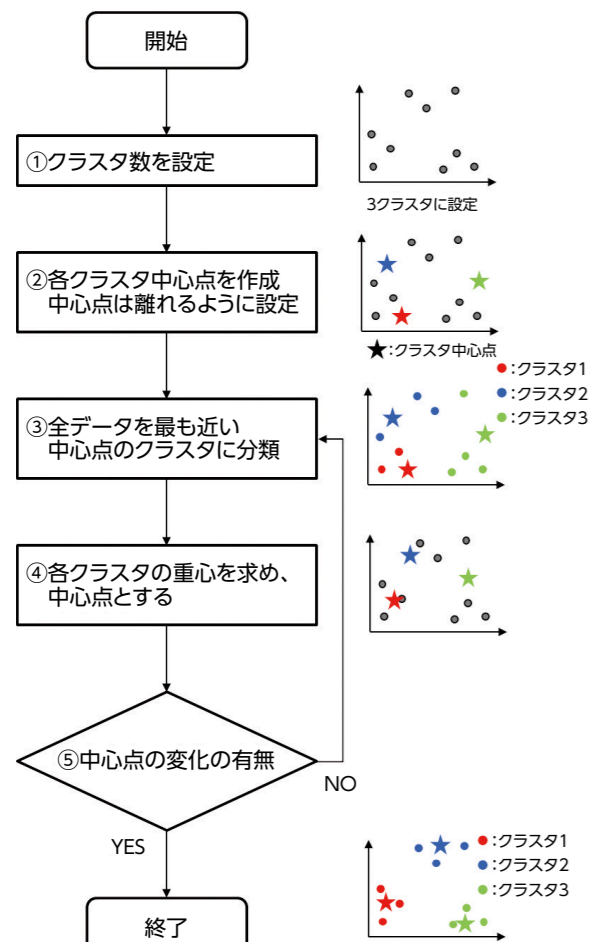


図7 K-means++によるクラスタリングの流れ  
Fig.7 Clustering flow with k-means++

前節で示したクラスター数の決定方法をもとに、K-means++でクラスタリングした結果、5クラスターにグルーピングすることで、不良率を34.6%低減可能な良品条件を見つけ出すことができた。

## 5 変化点検知モデルの開発

前章で定義した良品条件で生産できているかを監視するため、生産時に取得する時系列データに対して良品条件からの変化を検知する変化点検知モデルを開発した。なお、今回は1ショットあたり数十種類の時系列データを取得しているため、各種時系列データに対して変化点検知モデルを作成することで、どの時系列データに変化が発生したかを明確にする。

### 5.1 アルゴリズムの選定

高精度に変化を検知し、さらに変化を検知した際に変化箇所を提示することを目標としたため、機械学習手法であるAutoencoderを採用した。図8に示すように、Autoencoderはデータから

自動で特徴を抽出し、抽出した特徴をもとに復元する手法となっており、学習データに似た傾向のデータだけを正しく復元できる。そのため、学習データから傾向変化したデータは正しく復元できなくなっており、異常検知等に活用される手法である。図8に示すように、今回は前章で定義した良品条件の時系列データのみをAutoencoderの学習に使用することで、良品条件に似たデータだけを正しく復元可能なモデルの開発をする。また、学習済みのAutoencoderを用いて変化点検知を行う際には、入力データと復元データの誤差と閾値の比較により、変化の有無を判断する。

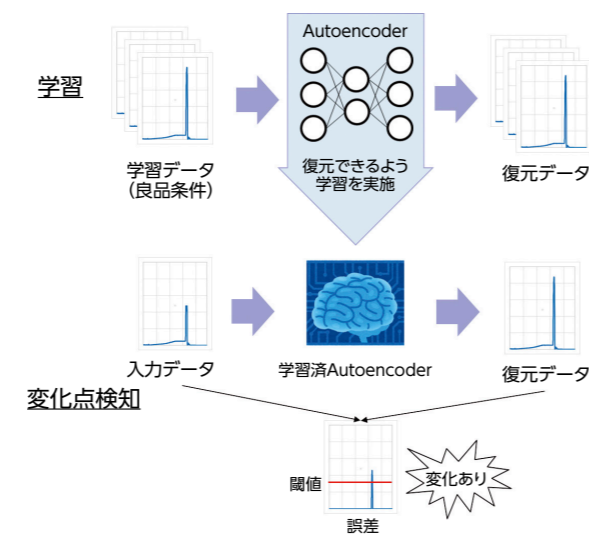


図8 Autoencoderの学習と変化点検知の方法  
Fig.8 Autoencoder training and method of change point detection

### 5.2 モデルの開発と精度確認

はじめに、良品条件のデータと良品条件以外のデータを用いて、図9のようにAutoencoderの学習に使用する学習データと閾値定義に使用する検証データ、変化点検知モデルの精度評価に使用するテストデータを作成した。

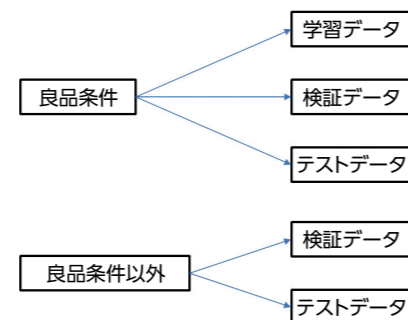


図9 データの分割方法  
Fig.9 Method of data division

次に、学習データを用いてAutoencoderの学習を行い、良品条件のデータを復元可能なモデルを作成した。そして最後に、学習済Autoencoderと検証データを用いて、良品条件からの変化を判断可能な閾値の定義を行った。

今回開発した変化点検知モデルを使用して、良品条件からの変化を検知した際には、図10のように入力データと復元データの誤差と入力データを同時に可視化することで、変化箇所を提示し、作業者の改善サポートを行う。




図10 変化箇所の可視化  
Fig.10 Visualization of change locations

変化点検知モデルの精度確認のため、テストデータを用いて良品条件と良品条件以外の各ショットデータを正しく判断する確率を調査した。その結果、両方の条件において、90%以上の確率で正しく判断できることが分かった(表1)。以上のことから、今回作成した変化点検知モデルは高精度に良品条件からの変化を検知でき、さらに誤検知が少ないことが確認できた。

表1 変化点検知モデルの精度  
Table1 Accuracy of change point detection model

	良品条件	良品条件以外
精度	98.5%	90.2%

## 6 監視ルールの定義

### 6.1 変化点検知モデルを用いた監視ルールの検討

前章に示した変化点検知モデルを活用した監視ルールの検討を行った。図5に示したとおり、現在取得している時系列データには異常値が混入しており、異常値を取得した際に誤検出することを防ぐため、複数ショットのデータを使用して、良品条件で生産できているかを監視する。監視方法は次の①~⑤の流れで実施する。

- ① 変化点検知モデルを活用して、1ショット目の各種時系列データが良品条件で生産できているかを確認
- ② 1種類の時系列データでも良品条件から変化している場合はそのショットを異常なショットと判断する
- ③ 検査対象のデータを次のショットに変更し、検査したショット数が指定した個数を超えるまで、①と②を繰り返す
- ④ 変化点検知した全てのデータを統合し、表2のようなデータセットを作成
- ⑤ 異常なショットの割合が閾値を超えている場合、良品条件から変化したと判断し、アラートを出力する

表2 良品条件からの変化点検知方法  
Table2 Method of detecting change points from good conditions

ショットNo	製造データ					結果
	A	B	...	C	D	
1	○	×	○	○	×	異常
⋮						⋮
N	○	○	○	○	○	正常

異常なショット数が閾値を超えた  
↓  
良品条件から変化した

### 6.2 精度確認・効果確認

はじめに、前節に定義した監視ルールの精度を確認するため、テストデータを用いて良品条件のロットと良品条件以外のロットを正しく判断する確率を調査した。監視ルールの精度と良品条件による低減不良率(34.6%)を掛け合わせた際、目標の低減不良率(30%)を達成するために、監視ルールの目標精度を90%とした。監視ルールの精度を確認した結果、良品条件と良品条件以外にも目標を達成していることが確認できた(表3)。

表3 監視ルールの精度  
Table3 Accuracy of monitoring rules

	良品条件のロット	良品条件以外のロット
精度	92.3%	93.2%

次に、効果確認のため、今回開発した技術を用いた監視システムの適応工数を調査した。その結果、2020年度の実証時に比べ、88%の工数削減が確認できた。

## 7 まとめ

2020年度に開発した監視システムの課題であった展開性の悪さに対して、AIの技術を活用し、人の分析作業を自動化することで、解消することができた。


今後は、本内容を他工程・他工場に広めていくことにより、全社のDX推進に貢献していきたい。また、本開発内容をアプリ化することにより、さらなる展開性向上なども検討していきたい。

最後に、本開発にご協力いただいた、コンプレッサ事業部 大府工場の皆様に、厚くお礼申し上げます。

### ■参考文献

- [1] “デジタルトランスフォーメーションを推進するためのガイドライン(DX推進ガイドライン)”. 経済産業省, 2018.  
[https://www.meti.go.jp/policy/it\\_policy/dx/dx\\_guideline.pdf](https://www.meti.go.jp/policy/it_policy/dx/dx_guideline.pdf),  
(参照 2022-05-19).

### ■著者紹介



末高 直樹

柴田 顕次

寺田 侑司

鈴木 祐輔

### 開発の経緯と開発者の思い

ビジネス環境が激しく変化する中、競争上の優位性を維持・確立するため、当社では様々なDX推進活動を行っております。その活動の一環として、働き方変革と機能強化を目指し、ダイカスト工程を対象に良品条件で生産できているかを監視するシステムの開発と実証を行い、成果を出すことができました。しかし、監視システムは他工程・他工場への展開毎に、分析作業が必要となる問題を抱えていたため、AIの技術を活用し、分析作業を自動化するしくみを開発しました。

今回、分析対象としたダイカストのデータはばらつきが大きく、データの種類も多いため、丁寧なデータの前処理やクラスタ数・監視ルールの決定方法の工夫が必要でしたが、ダイカスト工程やデータ分析に詳しい方々からのアドバイスのおかげで、無事に開発を完了することができました。

今回開発したモデルを用いることで、大幅に監視システムの展开工数を削減できたため、本システムを多くの工程・工場に展開していき、豊田自動織機のDX推進に貢献していきたいと思っております。