

# 高精度に機器の異常を検知するAI

AI-based High-precision Diagnostic Technology for Equipments

## 要旨

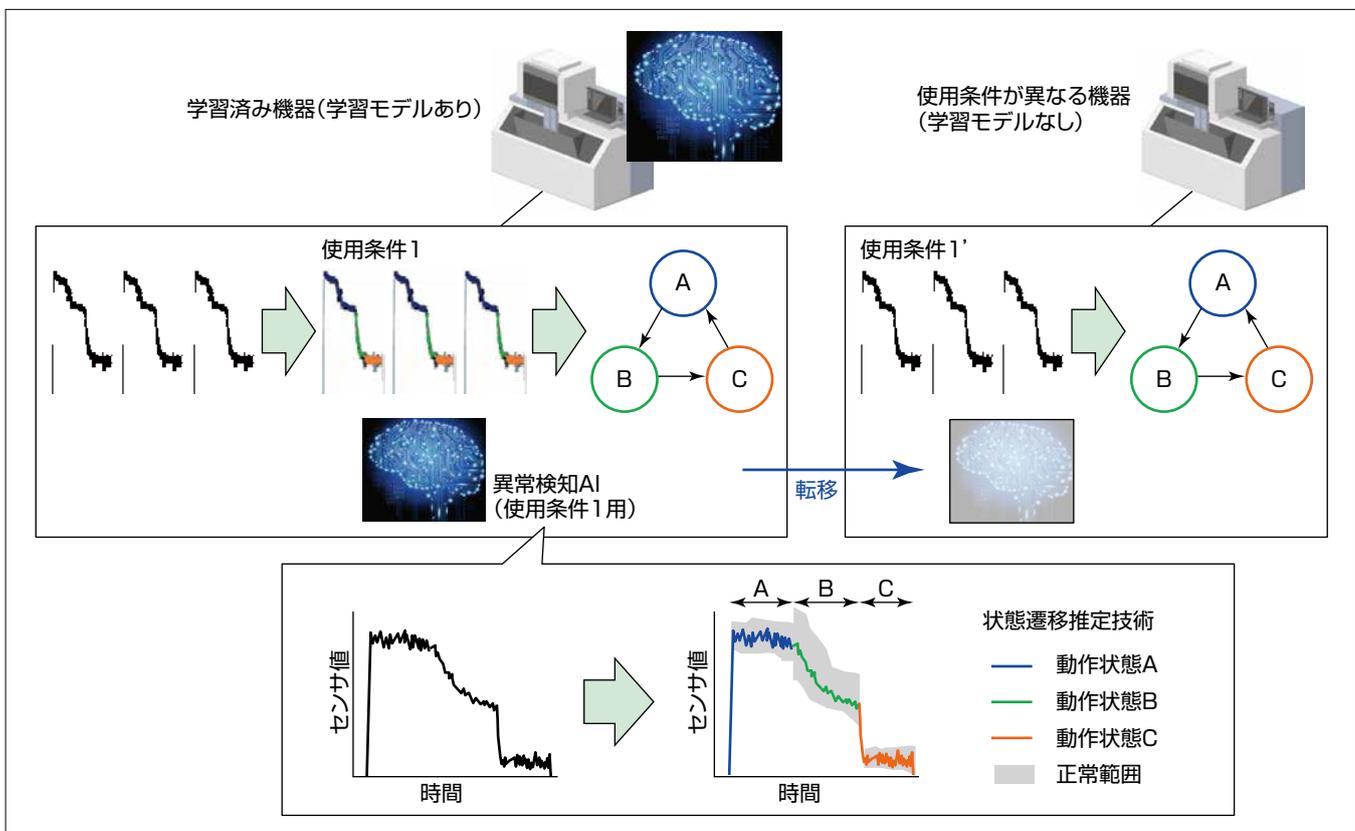
IoT(Internet of Things)技術の普及に伴い、設備や機器に設置されたセンサで計測された大量のデータを、クラウドやエッジ経由で随時取得することが可能になっている。随時取得可能な種々のセンサデータへAI(Artificial Intelligence)を活用することで、設備や機器のきめ細かな予防保全技術が実現されつつある。

異常検知を始めとした予防保全分野へのAIの活用では、設備や機器のセンサデータから、故障発生前にその予兆を検知し、故障発生前の保全を可能にすることで製造ラインのダウンタイムを削減し、効率的な保守が可能になることが期待される。

特に、製品製造時や機器運転時に収集される、時系列に発生するデータ(以下“時系列データ”という。)では、故障

予兆検出のために非常に微細な異常挙動を検出する必要がある。しかし、機器・設備の動作によって異常の頻度や異常時の波形の乱れ方が異なる場合があり、従来の単一条件設定による異常検知では、精度向上に限界があった。

動作による波形の乱れに対応するため三菱電機のAI技術“Maisart”を用いて、時系列データの特徴から動作状態の遷移を自動で推定し、動作状態ごとに適切な異常検知条件を自動設定することで、高精度に異常を検知する機器診断技術を開発した。この技術によって、機器の動作状態に応じた適切な異常検知条件が設定できるため、機器の異常を高精度に検知することが可能になった。また、この技術を応用し、予防保全技術の導入の容易化に向けた、使用条件の変化に対応可能な状態遷移推定技術を開発した。



## 使用条件が異なる機器のセンサデータに対する状態遷移推定技術の適用例

機器データの波形の特徴から機器の動作状態ごとに分割し、その遷移を推定することによって、機器の動作状態ごとに正常範囲を設定できる。これによって、高精度な異常検知が可能になる。また、一つの機器で学習した結果を使用条件が異なる機器に転移して活用することによって、新たに状態遷移を推定することなく、使用条件が異なる機器に対しても高精度に異常を検知できることが期待される。

## 1. ま え が き

近年、IoTの普及によって、設備などに設置したセンサーで計測したデータの活用にニーズが集まっている。特に、機器の予防保全分野では、設備の状態監視にセンサーデータを利用することによって、従来のあらかじめ決められた時期に決められたメンテナンスを行う“時間基準保全(Time Based Maintenance：TBM)”から、必要なときに必要なメンテナンスを行う“状態基準保全(Condition Based Maintenance：CBM)”へと保全の最適化への発展が期待されている。当社でも設備から収集したセンサーデータを利用した、異常検知技術を開発してきた。しかし、機器の高機能化によって、動作状態ごとにデータの特徴が異なる場合があり、高精度な異常検知技術の実現が課題であった。また、機器の使用条件によるデータのばらつきも考慮した異常検知も解決すべき課題である。本稿ではこれらの課題に対応した予防保全技術について述べる。

## 2. 機器向け状態遷移推定技術

保全の最適化のニーズに対応するため、機器の異常をきめ細かに監視し、最適な予防保全を実施する技術として、当社では、AI技術Maisartを用いた異常検知技術を持っている。

予防保全分野では、保全の最適化のほかに、予防保全技術の導入の容易化のニーズもある。従来の多くの異常検知技術では、同一機器で同様の動作条件で、既に学習済みの異常検知技術であっても、監視対象となる機器の使用条件(設置機器の外気温や稼働負荷等)が多様な場合、使用条件の特徴ごとにパラメータのチューニングが必要であった。そのため、データの蓄積や分析コストが膨大になり、同一機器であっても、使用条件が異なる機器が多い場合には、導入に障壁があった。

そこで、予防保全技術の導入の容易化のため、Maisartを用いた異常検知技術を応用し、使用条件が異なる場合でも汎用的に異常を検知可能な技術の開発に取り組んでいる。

対象とする機器のセンサーデータには、気温、振動、電流、電圧、回転数等多種・多様な情報があり、機器が稼働していた季節や頻度、負荷状況などを把握できる。機器の予防保全を実施する技術には、これらのデータから、次のテーマに沿った情報を抽出するための分析が含まれる。

### (1) 動作状態の推定

- ①分析対象：同じ傾向を示すデータのまとまり
- ②データの特徴：周期的な変動があるが、長期的な変動や突発的な変動が少ない、工程の変化を抽出可能なデータ

### (2) 異常検知

- ①分析対象：通常と異なる挙動
- ②データの特徴：長期的な変動や突発的な変動等があり、劣化の傾向を抽出可能なデータ

上記のテーマでは分析対象が異なるため、それぞれに望ましいデータの特徴を抽出するには、テーマに沿ったセンサーデータの取捨選択が必要である。

### 2.1 Maisartを用いた異常検知技術

Maisartを用いた異常検知技術は、まず、機器のセンサーデータから動作状態の移り変わりを表す“状態遷移モデル”を自動生成し、状態遷移を推定している。そして、推定した動作状態ごとに適切な異常検知条件を自動設定し、細やかに機器を監視することで、高精度に異常を検知している。ここでは、この技術について述べる。

製品製造時の機器の時系列データとして、次の3種類の特徴を持つデータを対象にする(図1)。

- (1) 類似波形が繰り返し発生
- (2) 製品製造時に複数の動作状態に遷移
- (3) 動作状態ごとにデータの特徴が相違

これらの特徴を持つデータに対して適用可能な異常検知技術として、データの正常範囲を求め、その範囲から逸脱した場合に異常として検知する方式<sup>(1)</sup>がある。しかし、故障の予兆は、製品製造時の機器の動作状態によって、データへの影響の出方が異なる場合がある。この場合、機器の動作状態を考慮せずに正常範囲を設定すると、範囲過大による異常の見逃しや、範囲過小による誤検知が発生するという課題がある(図2)。

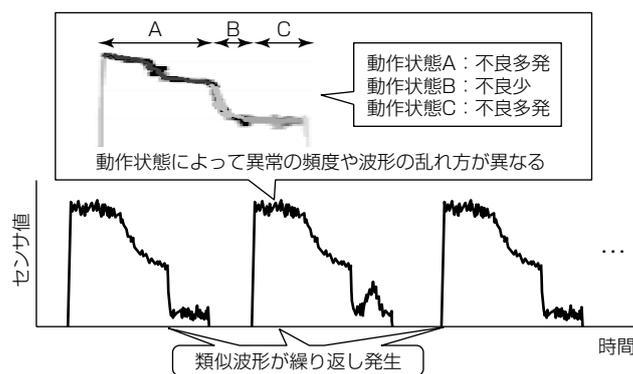


図1. 異常検知対象データの特徴

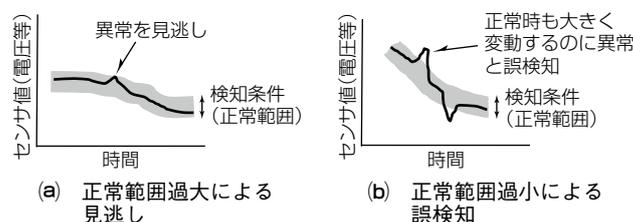


図2. 従来検知技術の課題

そこでこのような課題が存在する時系列データに対し、データの特徴から自動で機器の動作状態を推定し、動作状態ごとにデータを分割する技術を開発した(図3)。

時系列データを機器の動作状態ごとに分割し、動作状態ごとに異常検知条件を設定するための手順は次に従う。

- (1) 動作状態ごとにデータを分割し、移り変わり(状態遷移)を推定
- (2) 推定した状態遷移を基に動作状態ごとにデータを分割
- (3) 動作状態ごとに異常検知条件を設定

まず、製品の製造開始から終了までのデータ(以下“波形”という。)を動作状態ごとのデータに分割する。この際、動作状態の情報を別途収集している場合はそのデータを利用するが、今回はそうした情報が存在しないことを想定する。この場合、データの特徴から分割する必要がある。今回の対象データでは、変化の大きい点を動作状態の移り変わりの点として検出する。変化点検出の手法としてRDP(Ramer-Douglas-Peucker)アルゴリズム<sup>(2)</sup>を利用した。この手法では、波形の両端点を結んだ直線からの距離を基に、変化点を算出する手法であり、少ない計算量(O(n))で変化点の検出が可能である。

## 2.2 状態遷移の推定

2.1節で述べた手法をそのまま今回の対象データに適用した場合、変化の大きい部分に分割点が集中してしまう課題がある。そこで、所望の分割数より多く波形を分割し、その中から最適な分割点を選定する手法を開発した(図4)。

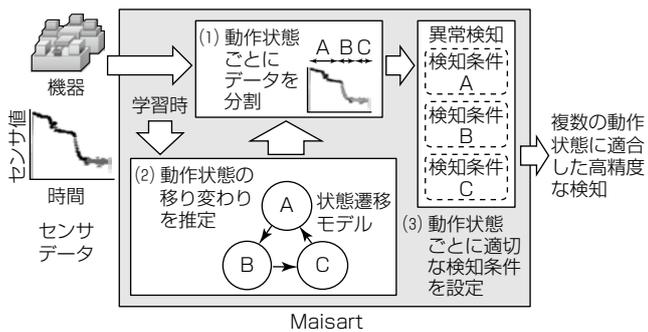


図3. 開発技術

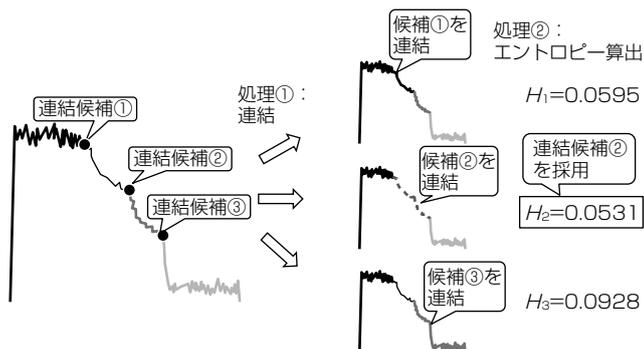


図4. 分割点の算出例

具体的には、多数の分割候補から機器の状態遷移のばらつきが最小となるような分割候補を選定する手法である。状態遷移のばらつきの指標には、状態遷移表のエントロピーを利用した。この手法によって、波形の分割点の選定失敗を防いだ上で、動作ごとに波形を分割可能にすることが期待される。

次に、この手法によって動作ごとに分割された波形(以下“部分波形”という。)に対し、動作状態ID(図3の“A”“B”“C”)を割り当てる。製品製造データでは、同一、又は類似の製品を連続して製造するため、同一動作での部分波形の形状は類似するものと考えられる。この仮定を基に、動作状態ID割当てをクラスタリング問題として捉える。なお、単純に動作の順番で動作状態IDを割り当てない理由としては、まれに設備の動作異常によって特定の動作がスキップされることがあり、その場合、動作状態ID割当てが失敗する可能性があるためである。また、動作の順番が必ずしも一定でない場合も考えられるため、今回は動作ごとの部分波形の形状ごとにクラスタリングする手法を採用した。具体的には、教師なし学習の一手法であるk-meansを利用した。この手法によって、部分波形を類似形状ごとに分類し、類似形状ごとに動作状態IDを附番する。動作状態IDが附番されることによって、動作の移り変わりの順番(状態遷移)、及びその確率も自動で学習することが可能になる。動作状態IDだけでなく状態遷移も併せて学習することによって、波形の乱れだけでなく、動作の遷移が学習時に見られないような挙動を示した場合にも異常を検知することが可能になる。

これらの手法によって、所望の分割数の入力だけから、データの特徴を利用した状態遷移推定が可能になることを示した。推定した状態ごとに、異常検知条件を設定することによって、状態ごとの動作の特徴に応じた正常範囲を設定することが可能になり、高精度な異常検知が可能になる。異常検知条件の設定には、各動作での部分波形から、各時刻のデータ分布を求め、その発生確率が $a\%$ (例： $a=1\%$ )以上になる部分を正常範囲とするなどの手法が考えられる。なお、今回対象にした製造機器のデータでは、各時刻のデータはおおむね正規分布に従うことを確認している。

図5は先に述べた異常検知技術を傾向の異なるデータへ適用した検証結果の例である。ここでは、まず、取得したセンサーデータそれぞれについて、同じ傾向を示すデータのまとまりから、波形の動作状態を推定し、推定結果に応じたデータの分割を実施する。その後、分割したデータごとの特徴を学習し、学習結果に基づき、通常と異なる挙動を示した箇所を異常として検知している。

傾向の異なるデータへ適用した場合でも、状態遷移の推定とデータの分割が実施可能である。さらに、推定に基づ

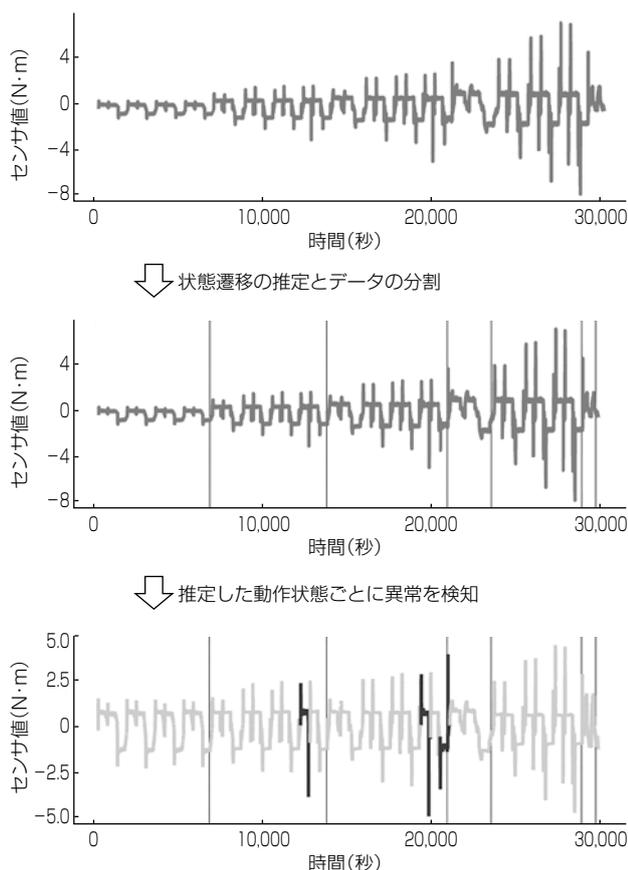


図5. Maisartを用いた異常検知技術の例

く異常検知が可能であることが分かった。

この技術を応用し、既に学習済みの異常検知技術を使用条件が異なる機器へ適用する方式を考察する。この場合の課題は、使用条件ごとに特徴が異なる点である。そこで、既存技術の動作状態ごとの特徴を把握する機能を、使用条件ごとの特徴の把握へ適用する。動作状態ごとの特徴は学習済みであるため、使用条件ごとの特徴と組み合わせることで、使用条件に応じた動作状態ごとの検知条件の設定が可能になる。

図6はこの技術による使用条件の異なる機器での異常検知技術の検証結果の例である。使用条件ごとに学習済みのモデルを補正し、状態遷移の推定を実施している。この状態遷移の推定結果に基づくデータの分割を実施し、分割したデータごとに検知条件を設定することで、通常と異なる挙動を示した箇所を異常として検知している。

使用条件の異なるデータへ学習済みのモデルを適用した場合でも、状態遷移の推定とデータの分割が実施可能である。さらに、推定に基づく異常検知が可能であることが分かった。この技術によって、異常検知技術を使用条件が異なる機器へ適用することで、予防保全技術の導入の容易化が可能になる。

### 2.3 異常検知率

この開発手法を実際の製品製造機器のセンサデータに適

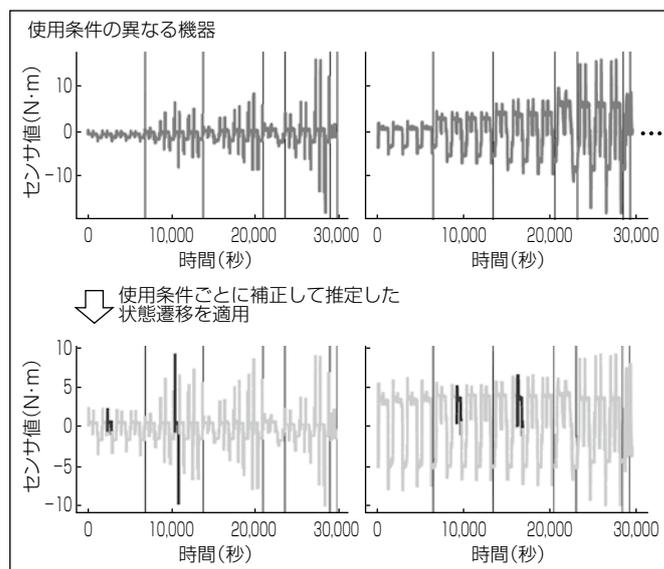
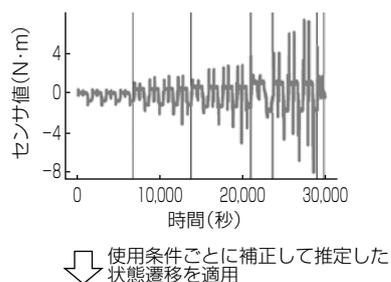


図6. 使用条件の異なる機器での異常検知技術の例

用したところ、状態推定を行わずに正常範囲を設定した場合には異常検知率85%であったのに対し、この手法を適用した場合、95%の異常を検出可能との結果を得て、この手法の有効性を確認した。

今後は、この技術を実際の製造現場に向けたツールとして開発し、実証実験を進めていく予定である。

## 3. む す び

予防保全技術へのAI適用による高精度化・省力化に向けた技術開発の取組みについて述べた。機器の高機能化に伴い、予防保全技術分野でのニーズは多様化していると考えられる。ニーズの多様化に対応するため、現場の知見やノウハウを吸収し、開発技術へ取り込むため、ドメイン知識の収集と実証実験の強化を実施していく。

### 参 考 文 献

- (1) Yeh, CC. M. : Matrix Profile I: All Pairs Similarity Joins for Time Series: A Unifying View that Includes Motifs, Discords and Shapelets, 2016 IEEE 16th International Conference on Data Mining (ICDM), 1317~1322 (2016)
- (2) Douglas, D. H., et al. : Algorithms for the reduction of the number of points required to represent a digitized line or its caricature, Cartographica : The International Journal for Geographic Information and Geovisualization 10, No.2, 112~122 (1973)