

AI技術を搭載した振動による 設備異常予兆検知システム 「VHERME[®] (ベルム) -AI」の開発

1. はじめに

当社ではこれまでに定格運転する機器（モーターやポンプなどの回転機器）の異常予兆検知を目的として、機器の振動データを取得し、MT法（マハラノビス・タグチ法）で解析して異常度を算出するシステム「VHERME（ベルム）」を開発し、社内外での実証試験を進めてきた¹⁾。

実証試験の一例として半導体製造現場で使用されている機器に対する技術検証を行った結果、機器由来の振動データのみから、異常予兆を捉えることが可能であることが見出された²⁾。

一方、これらの実証試験を進めていく中で、「異常度が顕著に表れない場合がある」「しきい値設定に必要な機器異常時の振動データを得ることが難しい」「機器の正常／異常を区別するしきい値の設定に作業者の経験が必要」といった課題が挙がってきた。

今回、上記の課題を解決するために、株式会社Ridge-iとAI技術（機械学習）を利用した異常予兆検知システムを開発した。このシステムの主要な開発目標は、解析技術の高度化による判定精度向上と、導入プロセスの簡易化（正常データのみを利用及び機械的で迅速なしきい値設定）であり、その結果、異常予兆検知システムの導入が容易になると考えている。本システムは、当社のVHERMEに実装されて

おり、その詳細について紹介する。

2. AIによる異常検知のトレンド

最初に、AI技術を活用した異常検知の一般的な手法について述べる。一般的に、AIによる異常検知方法は、Table1に示されるように、大きく次の3つの方法に分離される。

1つ目は、異常検知を主目的としない基盤モデルを用いて中間特徴量を取り出し、正常特徴量との距離を異常スコアとする方法である。この手法では、画像認識モデルなど既存の高性能モデルを利用出来るため、異常検知の性能はこれらのモデルの進歩に比例して向上する。しかし、正常の特徴量を保持する必要があるため、どの特徴量を代表的なものとして選択するかが重要であり、正常特徴のモデルリングに関する研究が盛んに行われている。

2つ目は、異常検知が行いやすいような中間特徴量に変換するAIモデルを学習する方法である。これはセンサーデータやテーブルデータなど、基盤モデルでは扱いづらいデータに対して有効である。この手法は異常検知に特化した特徴量に変換するため、精度の向上が期待出来る一方で、データの前処理と特徴量抽出に専門知識が必要となり、モデルの学習に時間と計算資源がかかる場合がある。

Table1 AIによる異常検知手法の分類

手法	特長	メリット	デメリット
基盤モデルを用いた 中間特徴量の異常スコア化	既存の高性能モデル（例：画像認識モデル）を利用し、中間特徴量を取り出して正常特徴量との距離を異常スコアとする方法。	・既存高性能モデルの進歩に比例して異常検知性能が向上	・正常特徴量の選択が重要
異常検知に特化した 中間特徴量変換モデル	異常検知が行いやすい中間特徴量に変換するAIモデルを学習する方法。センサーデータやテーブルデータなど基盤モデルでは扱いづらいデータに有効。	・異常検知に特化した特徴量に変換するため精度が向上 ・多様なデータ形式に対応可能	・データの前処理と特徴量抽出に専門知識が必要 ・学習に時間と計算資源が必要。
End-to-endモデル	データ入力から異常スコアの出力まで一貫してAIモデルが担う方法。	・一貫した処理が可能 ・モデルの自動化が進む	・モデルの複雑性が高く解釈性が低下 ・学習に大量のデータと計算資源が必要

3つ目は、データ入力から異常スコアの出力まで一貫してAIモデルが担うEnd-to-endモデルを学習する方法である。モデルの複雑性が高くなるため解釈性が低下することや、学習に大量のデータと計算資源が必要となる課題がある。

昨今の画像認識モデルの発展に伴い、基盤モデルを用いた異常検知の性能が飛躍的に向上することが期待出来る。また、センサーデータやテーブルデータに関しても、高性能な自然言語処理モデルの台頭により、これらを扱える基盤モデルが増えてきており、これらを用いた異常検知が注目されると考える。

3. 機械学習を利用した異常判定システムの開発

機械学習における手法、及びAIモデルの選定はいくつかの要因をもとに行っている。

画像や動画といったデータの特性によってどの基盤モデルが使えるか、異常データの割合によって教師あり、半教師あり、もしくは正常学習のどれで行うか、更に今後の運用によって再学習に対応したいかどうかなどが例として挙げられる。

モデル選定が完了すると次は実験フェーズに入り、候補で挙げたモデルに対して明確な仮説のもとで調整可能なパラメータを変えながら実験を行う。この実験フェーズにおいて判明したそれぞれのモデルの特性を観測データから推測し、パラメータの影響やしきい値の参考値、及びモデルの組み合わせ方法における知見が得られる(Figure1)。




Figure1 システム開発の流れ

例えば、今回の異常予兆検知では、異常データがほぼない前提であったため、モデルとしては正常学習AIを採用した。正常状態の振動データの特徴量を抽出し、その正常状態との距離から異常判定を行う手法を選定した。

4. 振動データへのAI適用検討

システム開発を進めるにあたり、振動データと機械学習手

法を組み合わせることによって、機器の異常を適切に判定可能であるかを検証した。

今回は市販機器を利用し、実験的に機器に対して異常を再現して検証を行った。機器の状態は正常から異常の9段階(Condition_1~9)とし、「Condition_1」を「正常」とし、数字が大きくなるほど異常度が高くなるように機器を調整した。

各状態での機器の振動データを収集し、可視化した結果をFigure2~4に示す。Figure2からは、異常度の変化とともに各パラメータに変化があることが確認出来る。Figure3、及びFigure4から、Mel Spectrogramからも正常状態と異常状態でデータの違いがあることが確認出来る。

また、各状態のデータの分類可能性についても検討した。今回は、PCA(主成分分析)、及びt-SNE(t-distributed Stochastic Neighbor Embedding)の2つの手法を利用した。Figure5にt-SNEで可視化した結果を示す。この結果から、正常状態とそれ以外の状態を分類可能であることが分かった。




Figure2 各状態の振動強度の変化




Figure3 正常状態(Condition_1)のMel Spectrogram




Figure4 異常状態 (Condition_9)のMel Spectrogram




Figure5 t-SNE結果

今回の開発では、正常時のデータのみでも運用開始可能とすることが目的の1つであった。そのため、いくつかの手法を検討した中で、クラスタリング手法の一つで、教師なし(異常時の学習アルゴリズムの一つであるk-means法)を利用した異常度の算出を試みた。

Figure6にk-means法を利用して算出した9つの各状態における異常度の変化を示す。また、統計手法を利用して算出したしきい値も同時に示している。今回の検討では、実験室において、人が機器の振動から異常を認知するよりも早く、AIモデルで算出した異常度に顕著な変化が認められることが分かった。

更に、今回作成した学習モデルの信頼性を検証するために、取得した振動データの一部をテストデータとして利用した検証結果をTable2に示す。この結果、正常状態を正しく判定出来る確率は95.2%、異常状態を正しく判定出来る確率は100%であった。




Figure6 k-means法で算出した異常度の変化としきい値

Table2 検証結果

		予測	
		正常	異常
正解ラベル	正常	95.2%	4.8%
	異常	0%	100.0%

5. VHERME[®]-AIの特長

振動データへのAI適用検討結果を活用し、VHERME-AIシステムを開発した。

VHERME-AIシステムは、当社がこれまで蓄積してきた振動データを利用した定格運転機器に対する異常検知ノウハウと株式会社Ridge-iのAI技術を組み合わせることによって、機器異常予兆検知における現場ニーズ・課題に柔軟に対応出来るシステムとなっている。

従来の異常検知システムでは、正常データと異常データの両方を用いてモデル学習する必要があり、加えて、学習後も正常と異常の境界を判定する「しきい値」の設定には専門的な知見を有する要員も必要であることから、モデル構築に労力を必要とし、運用においても「しきい値」の適正管理が難しいという課題があった。

現場ニーズ① 正常データと異常データを揃えるのに多くの時間を要するため、短時間で導入できるソリューションがほしい。
ソリューション センサー設置後、約1週間データをもとに異常検知モデルを作成し、現場運用が可能となる。

現場ニーズ② しきい値設定のノウハウが必要。しきい値を自動設定できるソリューションがほしい。
ソリューション しきい値の推奨値をAIが出力するため手軽に調整が可能。本システムでは正常データから統計的手法でしきい値の推奨値を提示する。




Figure7 VHERME-AI運用コンセプト

今回開発したAI技術を利用した異常予兆検知システムでは、正常データのみでモデルを構築・運用しながら、AIがしきい値の推奨値を提案することで、モデル構築の効率化と運用における課題を解消するものとなっている。

センサー設置後から1週間程度で現場運用が可能となり、しきい値の推奨値をもとに再学習を図り、継続的に判定精度が向上する仕様となっている(Figure7)。

6. VHERME[®]-AIのシステム構成

今回開発した解析ソフトは、バルカーがこれまでに開発してきたVHERME用のハードウェアをそのまま利用することが出来る。ここで簡単にVHERME用ハードウェアの紹介とシステム構成を示す。

Figure8に有機圧電素子を利用した振動センサーを示す。当社が開発した有機圧電素子を内蔵しており、薄型・小型軽量の特徴とした振動センサーとなっており、曲面や狭隘部に貼り付けることが可能である。また、マグネット式ブラケットを用いれば平面に限るが磁力での固定も可能である。



Figure8 有機圧電素子型振動センサー



Figure9 チャージアンプ内蔵8chセンサーユニット

Figure9にセンサーユニットを示す。本装置は、振動センサーから出力される電荷信号をチャージアンプを通してA/D変換し、振動データをPCに送信する機能を有しており、同時に8チャンネルの入力が可能となっている。

Figure10にシステム構成を示す。振動センサーとセンサーユニットはローノイズケーブルで接続され、センサーユニットに入力された振動データは、LANケーブルを通じてAI解析ソフトがインストールされたPCへ送信される。1台のPCで複数台のセンサーユニットを接続することが可能である。




Figure10 システム構成

本システムでは、あらかじめ収集した保全対象機器の振動データから前述した手順によって学習モデルを作成し、PCのAI解析ソフトに適用する。この時、推奨しきい値も適用される。

運用時は、システム算出する異常スコアとしきい値を比較し、各保全対象機器の状態(正常・注意・メンテナンス推奨・危険)が表示される。ユーザーはこの情報をもとに、保全対象機器の計画的なメンテナンスを実施することが出来る。

また、システムが表示する状態と機器の実態が異なる場合は、過去のデータを利用して、しきい値を再計算させることが出来るため、保全対象機器の実態により合致したしきい値による運用が可能となる(Figure11)。

更に、判定精度向上の方法として、学習モデルを更新する仕組みを備えている。この機能によって、前回の運用中のしきい値再計算による精度向上にとどまらず、学習モデル自




Figure11 VHERME-AIの画面(開発画面)

体を更新することが可能となり(同時に推奨しきい値も算出)、更なる判定精度向上を図ることが可能となっている。

なお、この解析ソフトでは、当社の有機圧電型振動センサーがカバーする周波数帯域(～20kHz)に加えて、更に高い周波数帯域(～100kHz)をカバーする他社製センサー(振動及び音波)のセンサーデータを利用することが可能となっており、保全対象の機器の種類や、異常予兆検知ニーズによって選択可能となっている。




Figure12 MONiPLATソリューション

7. 今後について

今後は、VHERME-AIの実証試験を進めていく予定である。同時に、バルカーが提供している設備点検プラットフォーム「MONiPLAT (<https://moniplat.com/>)」と連携し、CBMサービスの一つとしてより利便性の高いシステム・サービスへと進化させていく予定である(Figure12)。

ユーザーの皆様からのご意見ご要望をもとに、更なる改良を図っていく予定であり、忌憚ないご意見をいただきたいと考えている。

8. 参考文献

- 1) 佐藤 央隆：バルカー技術誌，No.41，12-15（2021）
- 2) 山下 裕也，佐藤 央隆，米田 哲也：バルカー技術誌，No.44，12-14（2023）

※MONiPLAT、VHERME、SealMote、VALVESTA、AlgoEyeは株式会社バルカーの商標または登録商標です。



横山 慶一
株式会社 Ridge-i
コンサルティング部



米田 哲也
技術総合研究所



佐藤 央隆
技術総合研究所