

説明性向上マルチモーダルAIによるMOCの潜在的異常見える化

中井 淳一
Junichi Nakai
若松 智之
Satoshi Wakamatsu

藤村 拓弥
Takuya Fujimura
戸田 智基
Tomoki Toda

浅野 憲司
Kenji Asano

概要

弊社では、主力製品であるMOC(Motor on Caliper)を題材にDX推進に向けた研究開発を行っている。MOCの複雑な機構から発生する複数の時系列データをマルチモーダルAIで処理し、異常の発生の予見を狙う。具体的には、異常の要因調査は、経験者(品管担当・設計者)の熟練したスキルが必要となるため、生産規模拡大時には経験者を増やさないといけない。しかし、経験者でも、MOCの異常の要因調査は、異常が増加してからでないと行えず、異常の兆候となる潜在的異常を捉えられていない。このような、広く自動車部品に共通する問題に対して報告する。この問題に対し、我々の提案手法は、AIならではの潜在的異常抽出を可能とし、異常の発生を予見する。

1. 背景

弊社では、主力製品であるMOC(Motor on Caliper)を題材に強力なDX推進に向けた研究開発を実施している。まずは、MOCの製造工程における最終工程の性能検査をその対象とする(図1参照)。その検査で異常が見つかった場合、その要因調査が行われる。しかし、現状、MOCの異常の要因調査は、異常が増加してからでないと行えず、異常の兆候となる潜在的異常を捉えられていない。

本稿では、事後の要因調査では気づけないAIならではの潜在的異常を抽出できるようにすることを狙う。AIを用い、正常時の状態監視をすることで、異常の兆候となる潜在的異常の増加を検知、それを未然に捉えることで、異常が発生する前に異常に気づくことを目指す。具体的には、MOCの複雑な機構から発生する、様々な波形を含む、複数の時系列データから、変化の傾向を特徴として抽出し、傾向監視して、潜在的異常を増幅し、AIで見える化する。




図1 MOCを題材としたAI活用

2. 提案手法

アーキテクチャは、基本的にデータ入力、クラスタリング、異常検知、データ処理で構成され、様々な種類の入力を扱えるマルチモーダルAIとなる(図2参照)。まず、データ入力として、設備に設置された種々のセンサを使用し、作動音、振動加速度、電流、荷重センサ電圧(クランプ力)などの様々な波形の時系列データを取得する。これらが性能検査のための複数の時系列データとなる。クラスタリングの前などに必要に応じて、複数の時系列データ内の波形を時間周波数特徴量(メルスペクトrogram)に変換し、時間的、周波数的な情報を扱いやすくする。

次に、複数の時系列データにクラスタリングを適用し、特徴的な波形のクラスタを抽出する。その波形のクラスタ内に正常な波形とは異なる特徴的な波形が多いにもかかわらず、これまで異常として認識できていない波形の場合、潜在的異常の可能性がある。そこで、その特徴的な波形のクラスタを潜在的異常として異常検知器に学習させる。それにより、潜在的異常を異常として検知可能となる。

潜在的異常を学習した異常検知器に日々の複数の時系列データを監視させ、潜在的異常度のヒストグラムを求めることで、潜在的異常が見える化し、異常の発生を予見する。

2.1 クラスタリング

認識・推定系AIにおける状態変化検出のための、クラスタリング(教師無し手法)により、複数の時系列データ

から、似た波形データを同じグループとして検出でき、潜在的異常の特徴を抽出する(図3参照)。それにより、潜在的異常の特徴を説明できるようになり、説明性が向上する。

本研究のクラスタリング手法は、PANNs¹⁾により波形データの特徴を抽出した後に、k-means²⁾を使用している。まず、波形データをメルスペクトログラムに変換し、PANNsを用いることで、特徴量を抽出する。

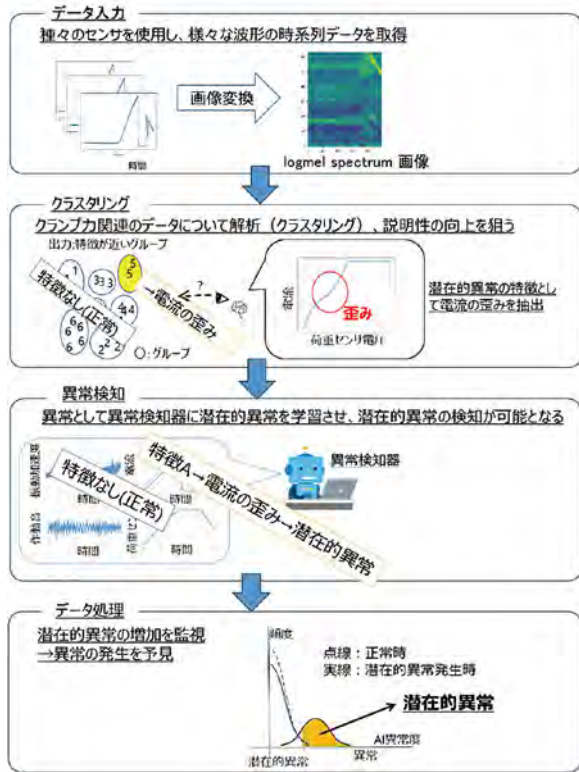


図2 構成フロー図 (データ入力+クラスタリング+異常検知+データ処理)

その特徴量にk-meansを使用し、得られたクラスタの中を目視で見て、特徴的な波形のクラスタを抽出する。このとき、正常の波形とは異なる特徴的な波形のクラスタが多くあるにもかかわらず、現状の検査閾値においては異常と判定していない波形が発見される場合がある。それらの波形を多く含むクラスタを、今まで気づいていなかった潜在的異常の波形のクラスタとする。検査閾値では正常だが、見た目は異常な波形となる。これは、潜在的異常の特徴抽出を意味する。

2.2 潜在的異常の検知

本研究では複数センサから得られる時系列データを監視するために、1次元CNN(Convolutional Neural Network)を用いて、潜在的異常検知器を作成する。この手法の流れとしては、まず、複数の時系列データの長さをアップサンプリングにより揃え、1次元CNNを用いて畳み込み、時系列情報を保持した特徴量に変換する。




図3 提案手法(クラスタリング)

このとき、クラスタリングで抽出した潜在的異常の特徴を含む複数の時系列データに潜在的異常のラベルを付けて、データを識別する識別学習³⁾を行うことで、潜在的異常を異常検知器に学習させた。また、正常品は正常として識別学習させているため、異常検知器は正常の中に埋もれた潜在的異常の検知が可能となる。この異常検知器の出力がAI異常度として、潜在的異常である確率を示す。




図4 提案手法(異常検知)

2.3 潜在的異常の分析

潜在的異常を学習した異常検知器に日々の複数の時系列データを監視させることで、潜在的異常の増加を監視できる。その監視のためにはそれらのデータをヒストグラム化する。

一例として、クランプ力を監視した場合を示す。クランプ力の異常が増加してからでないと、異常に気づけない。図5の上に横軸をクランプ力、縦軸をクランプ力の頻度とし、ヒストグラムの変化を監視した場合のイメージを示す。

潜在的異常を学習した異常検知器の出力されるAI異常度を監視することで、クランプ力の異常が増加する前に、潜在的異常の増加を捉えることができ、異常に気づける。図5の下に横軸をAI異常度、縦軸をAI異常度の頻度とし、ヒストグラムの変化を監視した場合のイメージを示す。




図5 提案手法(データ処理)

2.4 実験結果

図6に提案手法(マルチモーダルAI)を用い、実際の複数の時系列データのAI異常度を監視した結果を示す。異常度が高い所に正常の分布の山とは異なる分布の山が見られた。その異なる分布の山を強調し見やすくするため、横軸のlog scaleを取った結果を図6の右に示す。これにより潜在的異常の分布の山を見える化できる。この変化を監視することで、潜在的異常の増加を検知し、異常が発生する前に異常に気づける。




図6 提案手法(複数の時系列データを監視)

3. 提案手法の評価

3.1 潜在的異常検知精度

実際の波形データ(学習用1284個, 検証用131個)の潜在的異常判定を行った場合のROC曲線(Receiver Operating Characteristic curve)を図7に示す。真陽性率(=TPR)と偽陽性率(=FPR)に基づきAIの性能を総合的に表現している。グラフの下の部分の面積をAUC (Area Under the Curve)と呼び、0(0%)から1(100%)の値をとり、1(100%)に近いほど判定精度が高い。潜在的異常のAI検知精度(AUC)は73%となり、潜在的異常の山を見える化の上では、実用できるレベルと考えられる。




図7 潜在的異常の検知精度

3.2 考察

正常分布内(図6の①)、潜在的異常分布内(図6の②)の電流荷重センサ電圧波形をそれぞれ確認した結果を図8に示す。正常分布内の電流荷重センサ電圧波形は歪みがないのに対し、潜在的異常分布内の電流荷重センサ電圧波形には歪みが見られる。したがって、異常度の高さが正しく潜在的異常の可能性が高いことを表していることが分かる。

また、今回発見された潜在的異常である電流の歪みが原因で検査閾値を下回り異常となる事例も観測された。その概要を図9に示す。潜在的異常が増加することで、その中の一部がこのように異常となるため、異常増加の傾向を表していると思われる。これまで気づいていなかった異常増加の傾向を表している潜在的異常にAIを用いたことで気づくことができたと考えられる。

但し実際には、クランプカとして荷重センサ電圧を監視した場合は電流関連の波形に歪みが確かに見られるが、複数の波形に跨いて、影響が現れる可能性もある。そのような事象も今後捉えられるように、対象を増やしていく。

図8 正常分布内の電流荷重センサ電圧波形(図6の①) ・ 潜在的異常分布内の電流荷重センサ電圧波形(図6の②)



図8 潜在的異常分布内の波形




図9 潜在的異常(電流の歪み)による異常増加の傾向

4. おわりに

MOCの製造工程における最終工程の性能検査において、異常が見つかった場合、その要因調査が行われ

る。しかし、現状、MOCの異常の要因調査は、異常が発生してからでないと行えず、異常の兆候となる潜在的異常を捉えられていない。

本研究では、提案手法により、人による要因調査では気づけないAIならではの潜在的異常を抽出できるようにすることを狙った。AIを用い、正常時の状態監視することで、異常の兆候となる潜在的異常の増加を検知、異常の発生を予測するための検討を行った。具体的には、MOCの複雑な機構から発生する複数の時系列データから、変化の傾向を特徴として抽出し、傾向監視して、潜在的異常を増幅し、AIで見える化した。

その結果、潜在的異常を検知し、強調、監視することで、見える化が可能となった。それにより、異常が発生する前に異常に気づくことができるようになった。潜在的異常のAI検知精度は73%となり、潜在的異常の山に見える化する上では、実用化できるレベルであると考えられる。

今後、AI側で異常の要因調査までたどり着けるように、新しい機能を追加していく(図10参照)。具体的には、マルチモーダルAIに、言語情報も含めて異常の発生を予測する、新しい機能を追加し、本研究で見つかった潜在的異常も含む異常について、異常の要因と関連がありそうな言語情報を紐づけ、異常に関する要因を言語で説明可能とし⁴⁾⁵⁾⁶⁾、要因調査を自動化する。さらに、そのAI内部で行われている判断の過程を見える化することで、異常と要因情報を因果グラフとして見える化し、通常FMEA、FTAなどを用いて行われる要因分析までも、マルチモーダルAIに機能を追加し、自動化していく。要因調査の負担が大幅に減少するため、有用であろう。

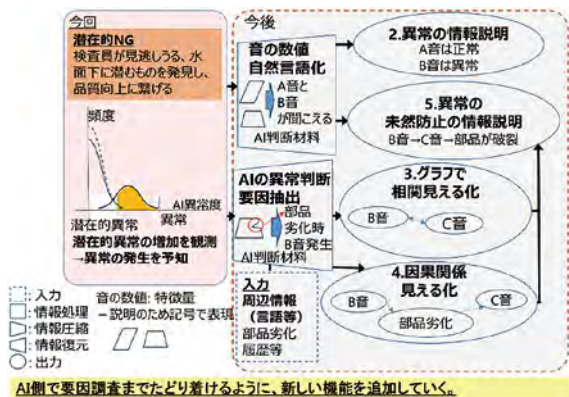


図10 マルチモーダルAIへの機能追加

参考文献

1) Kong, Q., Cao, Y., Iqbal, T., Wang, Y., Wang, W., Plumbley, M. D. (arXiv): PANNs: Large-Scale Pretrained Audio Neural Networks for Audio Pattern Recognition, 1912.10211, 2016.
 2) Steinley, D., Brusco, M. (Journal of Classification 2007): Initializing K-means Batch Clustering: A Critical Evaluation of Several Techniques, Springer nature link, 2007.

3) Thoidis, I., Giouvanakis, M., Papanikolaou, G. (MDPI Electronics): Semi-Supervised Machine Condition Monitoring by Learning Deep Discriminative Audio Features, 10(20), pp.2471, 2021.
 4) Gulati, A., Qin, J., Chiu, C., Parmar, N., Zhang, Y., Yu, J., Han, W., Wang, S., Zhang, Z., Wu, Y., Pang, R. (arXiv): Conformer: Convolution-augmented Transformer for Speech Recognition, 2005.08100, 2020.
 5) Ribeiro, M. T., Singh, S., Guestrin, C. (arXiv): "Why Should I Trust You?": Explaining the Predictions of Any Classifier", 1602.04938, 2016.
 6) Kamble, M., Krishna, M. V. S., Pulikonda, A. K. S., Patil, H. (PREMI 2019): Novel Teager Energy Based Subband Features for Audio Acoustic Scene Detection and Classification, Lecture Notes in Computer Science, pp.436-444, 2019.
 7) Chen, S., Wu, Y., Wang, C., Liu, S., Trompkins, D., Zhuo, C., Wei, F. (arXiv): BEATS: Audio Pre-Training with Acoustic Tokenizers, 2212.09058, 2022.
 8) Schlegl, T., Seebock, P., Waldstein, S. M., "Schmidt-Erfurth, U., Langs, G. (IPMI): Unsupervised Anomaly Detection with Generative Adversarial Networks to Guide Marker Discovery, 2017.
 9) Xu, K., Ba, J., Kiros, R., Cho, K., Courville, A., Salakhutdinov, R., Zemel, R., Bengio, Y. (arXiv): Show, Attend and Tell: Neural Image Caption Generation with Visual Attention, 1502.03044, 2015.
 10) Zenati, H., Foo, C. S., Lecouat, B., Manek, G., "Chandrasekhar, V. R. (ICLR): Efficient Gan-based Anomaly Detection, 2018.

筆者



中井 淳一
 株式会社アドヴィックス
 システム企画開発部
 マルチモーダル説明AIの研究に従事



藤村 拓弥
 名古屋大学
 情報学研究科
 音メディア情報処理の研究に従事



浅野 憲司
 株式会社アドヴィックス
 ビジネスプロセス革新部
 DX推進, 人材育成に従事



若松 智之
 株式会社アドヴィックス
 システム企画開発部
 マルチモーダル説明AIの研究に従事



戸田 智基
 名古屋大学
 情報基盤センター
 音メディア情報処理の研究に従事