

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 Introducing Multimodal AI with improved explainability into a Potential Anomaly prediction for Motor on Caliper Inspection

中井 淳一[†] 藤村 拓弥[‡] 高田 将典[†] 浅野 憲司[†] 若松 智之[†] 戸田 智基[‡]
Junichi Nakai Takuya Fujimura Masanori Takada Kenji Asano Satoshi Wakamatsu Tomoki Toda

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。

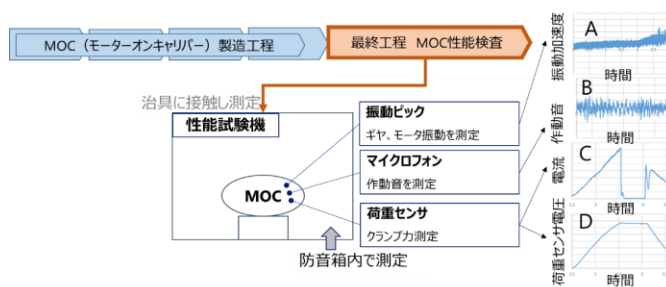


図 1 MOC を題材とした AI 活用

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(メルスペクトログラム)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、

[†]株式会社アドヴィックス ADVICS CO., LTD.

[‡]名古屋大学 Nagoya University

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、潜在的異常に見える化し、異常の発生を予測する。

2.1 クラスタリング

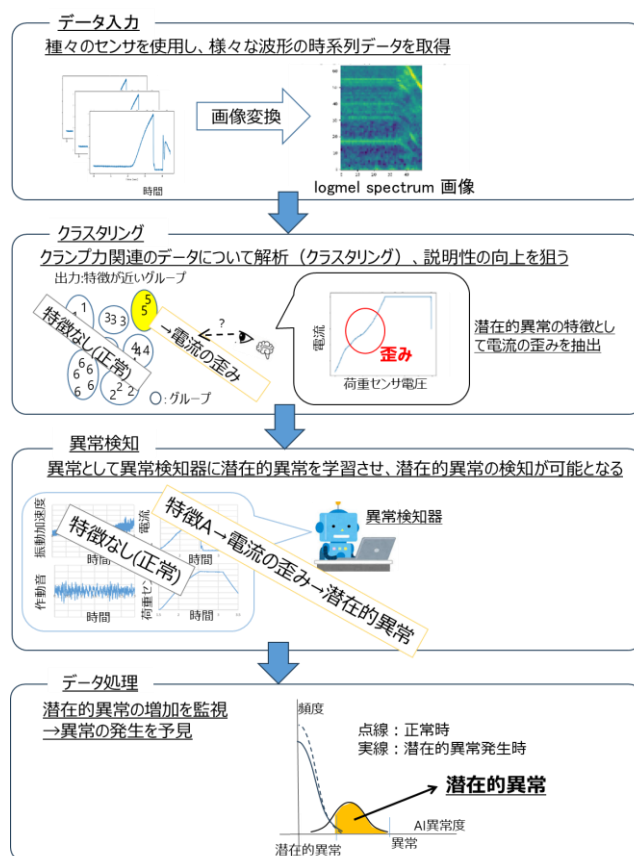


図 2 構成フロー図(データ入力+クラスタリング+異常検知+データ処理)

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、PANNs[1]により波形データの特徴を抽出した後に、k-means[2]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 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する上では、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、クランプ力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。

・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、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、潜在的異常の山を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。

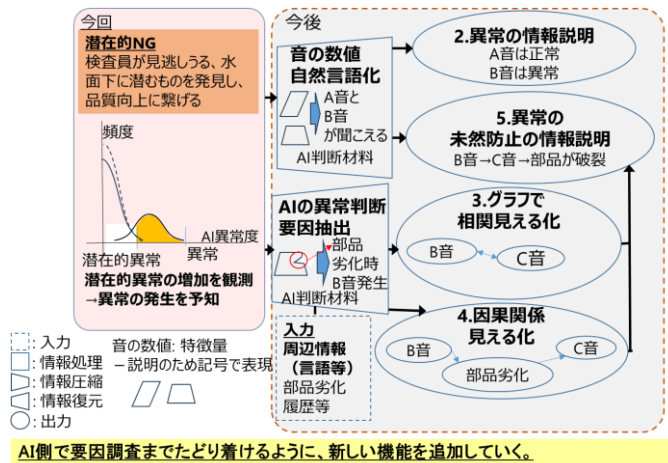


図 10 マルチモーダル AI への機能追加

参考文献

- [1] Kong, Q., Cao, Y., Iqbal, T., Wang, Y., Wang, W., Plumbley, M. D., "PANNs: Large-Scale Pretrained Audio Neural Networks for Audio Pattern Recognition", arXiv, 1912.10211 (2016).
- [2] Steinley, D., Brusco, M. "Initializing K-means Batch Clustering: A Critical Evaluation of Several Techniques, Springer nature link", Journal of Classification 2007 (2007).
- [3] Thoidis, I., Giouvanakis, M., Papanikolaou, G., "Semi-Supervised Machine Condition Monitoring by Learning Deep Discriminative Audio Features", Vol. 24, pp. 99–121 (2021).
- [4] Gulati, A., Qin, J., Chiu, C., Parmar, N., Zhang, Y., Yu, J., Han, W., Wang, S., Zhang, Z., Wu, Y., Pang, R., "Conformer: Convolution-augmented Transformer for Speech Recognition", arXiv, 2005.08100 (2020).
- [5] Ribeiro, M. T., Singh, S., Guestrin, C., "Why Should I Trust You?": Explaining the Predictions of Any Classifier", arXiv:1602.04938 (2016).
- [6] Kamble, M., Krishna, M. V. S., Pulikonda, A. K. S., Patil, H., "Novel Teager Energy Based Subband Features for Audio Acoustic Scene Detection and Classification, Lecture Notes in Computer Science", PReMI 2019, pp.436-444 (2019).
- [7] Chen, S., Wu, Y., Wang, C., Liu, S., Tromplins, D., Zhuo, C., Wei, F., "BEATs: Audio Pre-Training with Acoustic Tokenizers", arXiv, 2212.09058 (2022).
- [8] Schlegl, T., Seebock, P., Waldstein, S. M., "Schmidt-Erfurth, U., Langs, G. : Unsupervised Anomaly Detection with Generative Adversarial Networks to Guide Marker Discovery", IPMI (2017).
- [9] Xu, K., Ba, J., Kiros, R., Cho, K., Courville, A., "Salakhutdinov, R., Zemel, R., Bengio, Y. : Show, Attend and Tell: Neural Image Caption Generation with Visual Attention", arXiv:1502.03044 (2015).
- [10] Zenati, H., Foo, C. S., Lecouat, B., Manek, G., "Chandrasekhar, V. R. : Efficient Gan-based Anomaly Detection", ICLR (2018).