

回転機器状態監視のための振動異常検知システムにおける特徴表現学習

Feature Representation Learning of Vibration-based Anomaly Detection for Rotation Machinery Condition Monitoring

長谷川 隆徳 *1*2
Takanori Hasegawa

緒方 淳 *2
Jun Ogata

村川 正宏 *2
Masahiro Murakawa

小川 哲司 *1*2
Tetsuji Ogawa

*1 早稲田大学基幹理工学研究科

Waseda University The School of Fundamental Science and Engineering

*2 産業技術総合研究所人工知能研究センター

AIST Artificial Intelligence Research Center

The present paper describes neural network (NN)/Gaussian mixture model (GMM) tandem connectionist anomaly detection to efficiently develop and operate condition monitoring systems. The key to the success for that purpose is robust feature representation learning that effectively exploits normal-state and faulty-state data collected from non-target machines. Experimental comparisons conducted using vibration signals from actual wind turbine components demonstrated that NN/GMM tandem system developed using faulty-state data from non-target machines yielded significant improvements over the existing system, and that NN/GMM system developed using only normal-state data from target and non-target machines also performed better than the existing system.

1. はじめに

観測可能なデータを効率的に利用することで、監視対象の違いに対して頑健に高い精度で異常の検知を可能にする方式を提案する。

近年、産業分野においてデータ駆動型異常検知の需要が高まっている。データ駆動型異常検知は、一般的に、入力信号から監視対象の正常と異常を識別することで異常状態を検知するアプローチと、正常状態からの外れ値として異常を検知するアプローチに大別される。このとき、特に大型産業機械においては、損傷の発生が稀であるため、監視対象機器における異常状態の観測を前提とした正常・異常識別に基づくアプローチは現実的でないことが多い。さらに、風車等の産業機械は、機械を構成する主要機器の構造が複雑であるため、損傷が発生したとしても観測されるパターンは膨大である。そのため、正常データと異常データの双方を網羅的に収集し、正常と異常の2クラスに分類するモデルを構築するのは容易ではない。

そこで、一般的なデータ駆動型異常検知システムは、外れ値検知のアプローチにより構築されることが多い。このアプローチでは、監視対象機器の正常稼働状態のデータのみで正常状態モデルを構築する。そして、正常モデルに対する尤度がある閾値を下回る入力を異常と判定する。実際に我々は、特徴量としてフーリエ局所自己相関特徴 (Fourier local auto-correlation features; FLAC) [Ye 10, Jiaying 10] を用い、正常状態を混合ガウス分布 (Gaussian mixture model; GMM) によりモデル化した異常検知システムを構築し、風車実機から取得した振動データに対して有効性を明らかにした [Ogata 16]。このとき、正常状態であっても、機械周辺の気象や運転状況ならびに設置環境などにより、振動は変動する。このとき、未知の正常状態に対しても頑健なモデルを構築するために正常状態モデルの汎化性能を単純に高めようとすると、未知の異常を見逃す可能性が増大することに注意すべきである。

それに対して本研究では、監視対象機器以外から取得した正常や損傷データを効率的に用いて、監視対象の違いに依らず

頑健に異常を検知するための本質的な特徴表現を抽出することで、異常検知システムを汎化させることを試みる。本稿では、風車実機から得られる振動データを用いた実験により、提案手法の有効性を明らかにする。

本稿の構成は以下の通りである。2. では、正常・異常識別と照合のアプローチに基づく関連研究について述べる。3. では、監視対象外の機器から得られた損傷データを有効に活用するアプローチとして、deep neural network (DNN)/GMM タンデム接続型異常検知について述べる。4. では、損傷データが全く利用できない場合に適用可能な auto-encoder (AE)/GMM タンデム接続型異常検知を説明する。5. では、風車実機データを用いた異常検知実験について述べ、最後に 6. にてまとめを述べる。

2. 関連研究

本章では、産業用回転機器の中で最大級の大きさを誇る風力発電用主要機器の監視に焦点を当て、データ駆動型異常検知に関する関連研究と本研究の位置づけについて述べる。

[Bach-Andersen M 17] では、自社でサービス展開している実機風車に対する長期的なデータ計測により、251 件の軸受損傷事例における損傷振動データと通常稼働時において収集される正常振動データを収集し、正常と異常を識別する畳み込みニューラルネットワークを構築している。このように、大規模な軸受損傷データが利用可能であれば、高精度な正常・異常識別器が構築可能である。しかしながら、こうしたアプローチは識別器の学習時と運用時において同型の風車機器に対するデータ収集が前提となり、学習時に考慮されていない機器に対しての異常検知性能は保証されない。また、監視対象や監視対象と同型の機械から損傷データが十分に収集されるまで識別器を構築できないことから、このようなアプローチによって構築される異常検知システムは早期の運用が困難である。

[Purarjomandlangrudi 14] では、風車を模擬した装置から取得した振動データを用いて異常検知実験が行われている。正常稼働振動データのみから、特徴量として尖度と非ガウス性スコアを抽出し、one-class SVM により正常状態モデルを構築

連絡先: 長谷川 隆徳, 早稲田大学, 基幹理工学研究科,
hasegawa@pcl.cs.waseda.ac.jp

している。実験結果は、損傷データが観測されない状況でも、風車主要機器の異常予兆を検知できる可能性を示唆している。しかし、監視対象の機器から収集されたデータのみを用いることを前提としており、他機器から観測されたデータの効率的な利用を想定していないことは本研究とは異なる。

このような機器ごとの環境の違いに対しては、多様な機器から観測されたデータを効率的に用いてシステムを汎化させることが望ましい。このとき、正常状態モデルを汎化させようとすれば、未知の正常状態に対しては頑健になる一方で、未知の異常状態の検知が困難になる可能性がある。本研究は、正常状態モデルを汎化させるのではなく、多岐に渡る性質のデータを用いてデータ駆動型の特徴抽出器を構築し、回転機器の正常稼働状態を表す本質的な特徴や、正常と異常状態を区別するための本質的な情報を抽出することで、異常検知システムを効率的に構築しようという試みである。

3. DNN/GMM タンデム接続型異常検知システム

損傷データが得られた場合、それを異常検知のための特徴抽出器の構築に利用する。提案の基本となる DNN/GMM タンデム接続型アプローチに基づく異常検知システムにおける処理フローを図 1 に、識別的な特徴抽出器のネットワーク構造を図 2 に示す。図 2 に示した DNN は正常状態と損傷状態を識別する 7 層の全結合型ニューラルネットワークであり、5 層目にボトルネック層（他の隠れ層よりもユニット数を絞った層）を有する。このボトルネック層出力は、機器の正常時と損傷時の識別に寄与する情報のみを低次元で表現しようとするものであり、異常の検知性能の向上に直結することが期待できる。このとき、ボトルネック層の出力をボトルネック特徴量と呼び、この特徴量を用いて GMM を用いた照合に基づく異常検知を行う。この枠組みを DNN/GMM タンデム接続型異常検知システムと呼ぶ。

前述の通り、ボトルネック特徴は機器の正常・損傷状態を識別する DNN を通じて得られる。しかし、機器に損傷が生じるのは稀であり、モニタリングの対象となる機器において損傷データが大量に得られることを仮定するのは現実的ではない。そこで、正常・損傷状態識別用 DNN は、モニタリング対象とは異なる機器で観測された正常・損傷データを用いて構築するものとする。

いま、DNN の入力、振動波形の短時間スペクトルに対するメルフィルタバンク出力である [Sigurdsson 06]。DNN は、入力される振動が正常状態であれば 0、損傷状態であれば 1 を出力するように学習する。ここでは、入力の次元数（メルフィルタバンク数）は 15、中間層は 32 ユニットとする。また、ボトルネック層のユニット数は、実験的に決定する。

4. AE/GMM タンデム接続型異常検知システム

3. で述べた方式では、監視対象機器とは異なるものの損傷状態の振動データを利用している。それに対し、損傷状態のデータが全く観測されない状況においても、高性能な異常検知システムが構築できれば、監視システムの実運用において有益となる。

そこで本研究では、監視対象機器やそれに類似した機器の正常稼働状態のデータのみを用いて構築したオートエンコーダのコンパクトな中間層出力を特徴表現として用い、正常状態

の照合を行う GMM に入力することで機器の異常検知を行う。この枠組みを AE/GMM タンデム接続型異常検知と呼ぶ。処理フローは図 1 に示したものと同様であるが、特徴抽出器学習の段階で正常データのみを用いる点異なる。また、特徴抽出器として用いるオートエンコーダの構造を図 3 に示す。このオートエンコーダは 7 層の全結合型ニューラルネットワークであり、4 層目にボトルネック層を持つ。正常データのみを用いて入力を復元するように学習することで構築する。このとき、入力からボトルネック層までのエンコーダ部分が特徴抽出に相当する。このオートエンコーダを、監視対象機器を含む複数機器の正常データを用いて学習するとき、ボトルネック層出力には機種や機器の違いに依らない正常稼働状態とは何か、を表す本質的な情報が含まれていると期待できる。このボトルネック層の出力を特徴量として後段の GMM に基づく異常検知器の入力に用いることで、異常検知性能の向上が期待できる。

いま、オートエンコーダの入力には、FLAC 特徴量を用いる。このとき、入力の次元数は 75、中間層は 64 と 32 ユニットを適用する。また、ボトルネック層のユニット数は、実験的に決定する。

5. 異常検知実験

タンデム接続型異常検知システムの有効性を検証するために、NEDO 事業「スマートメンテナンス技術研究開発（分析）（リスク解析等）」において収集された風力発電機実機の Condition Monitoring System(CMS) データ（加速度振動データ）を用いて異常検知実験を行った。

5.1 振動データ

本研究で用いる振動データセットについて述べる。監視対象機器は風力発電機の主軸受（回転速度：19.4 rpm）であり、NTN 社製計測装置 [Takeuchi 12] により取得された加速度振動データである。計測は設置された加速度ピックアップにより 1 回あたり 40 秒の振動データが記録され、この計測が 2 時間間隔で行われた。サンプリング周波数は 25.6kHz である。本実験で使用する主軸受振動データ A.07 および B.21 は、それぞれ異なるサイトで取得されたものであり、風車の機種も異なる。また、モニタリング対象の主軸受の形式はいずれも自動調心ころ軸受であるが、主要寸法等スペックは異なる。各主軸受の損傷状況は、A.07 が「軌道面の剥離損傷」、B.21 が「転動体ならびに軌道面の剥離損傷」であった。各データセットの正常・損傷状態の計測回数（記録された振動データ数）を表 1 に示す。

風車サイト・号機	表 1: データセットのデータ量	
	収録計測数	
	正常データ	異常データ
A.07	2050	1304
B.21	1331	1033

5.2 比較システム

本実験では、以下の 3 つのシステムの異常検知性能を比較した。

1. **FLAC-GMM**: 監視対象機器から取得した入力データに対して FLAC 特徴量を抽出し、監視対象機器の正常データで構築した GMM により正常状態モデルを構築する。




図 1: タンデム接続型異常検知システムの処理フロー




図 2: DNN/GMM タンデム接続型異常検知システムの概要図

2. **DNN/BNF-GMM**: DNN/GMM タンデム接続型異常検知システム。前段のボトルネック特徴抽出器 (DNN) は、監視対象とは異なる機器から取得された正常ならびに損傷データから構築し、異常検知器としての照合器 (GMM) は監視対象機器の正常データのみから構築する。
3. **AE/BNF-GMM**: AE/GMM タンデム接続型異常検知システム。前段のボトルネック特徴抽出器 (AE) は、監視対象と監視対象外の機器から取得した正常データを用いて構築し、照合器 (GMM) を監視対象から取得された正常データから構築する。

このとき、振動波形フレーム長は 5.12 秒である。**AE/BNF-GMM** では、1 フレーム分の FLAC 特徴量出力 75 次元をオートエンコーダの入力とした。また、**DNN/BNF-GMM** では、1 フレーム分のフィルタバンク出力 15 次元を DNN の入力とした。ボトルネック層のユニット数はそれぞれ **AE/BNF-GMM** では 16 を、**DNN/BNF-GMM** では 8 とし、GMM の混合数は全て 8 とした。

5.3 実験

図 4 および図 5 に、A.07 および B.21 に対して異常検知を行った場合の ROC 曲線と AUC 値をそれぞれ示す。例えば、A.07 を監視対象の主軸受とすると、**DNN/BNF-GMM** では B.21 の正常・損傷データから DNN を構築し、**AE/BNF-GMM** では A.07 と B.21 の正常データから AE を構築する。図 4、図 5 より、**DNN/BNF-GMM** システムの性能が最も高いも




図 3: AE/GMM タンデム接続型異常検知システムの概要図




図 4: A.07 を監視対象としたときの ROC 曲線と AUC 値

の、システム構築に損傷データを一切用いない **AE/BNF-GMM** システムにおいても **DNN/BNF-GMM** システムに匹敵する性能を達成することができた。

これより、貴重な損傷データが取得できた場合には異常状態のデータを陽に与えることにより特徴抽出器を DNN により構築することで、正常と異常を識別するに十分な特徴表現を照合器に入力できるため非常に精度の高い異常検知が可能となる。一方、一切損傷データがシステム構築のために利用できない場合においても、他機器から取得した正常データから正常状態に関する特徴表現を学習し獲得することで従来手法に比べ高性能な異常検知システムが構築できることを明らかにした。




図 5: B.21 を監視対象としたときの ROC 曲線と AUC 値

6. おわりに

本研究では、異常検知システムの汎化に関する一検討として、機器や環境の違いに頑健な特徴表現の抽出手法を提案した。監視対象とは別の類似機器で損傷データが観測された際には、正常と損傷を区別するための本質的な特徴表現を獲得することを試み、正常状態モデルに対する照合に用いた (DNN/GMM タンデム接続型異常検知システム)。また、異常検知システムの構築において損傷データを一切利用できない状況においては、監視対象機器とそれ以外の機器から取得した正常データを用いてオートエンコーダ構築し、その中間層出力を機器の違いに依らず正常状態を表現する特徴とみなした (AE/GMM タンデム接続型異常検知システム)。風車実機から収集された振動データを用いて異常検知実験を行ったところ、提案する特徴表現の利用により人手で設計した特徴表現に基づくシステムの性能を大幅に改善できることが明らかになった。このとき、損傷データを特徴抽出器の構築に利用する DNN/GMM タンデム接続型異常検知システムが最良の性能を与えた。また、損傷データを一切使用しない AE/GMM タンデム接続型のシステムも既存システムを上回る性能を達成した。以上のように、1) 監視対象機器からは少量の正常データが観測され、監視対象以外の機器からは正常データに加えて損傷データも観測できる場合と、2) 損傷データを一切観測できない場合という、現実的な 2 つの想定において、提案システムは、従来システムの異常検知性能を著しく向上することに成功した。

謝辞

本研究の一部は、NEDO 事業「風車運用高度化技術研究開発」による支援を受けた。本実験で使用した CMS データの収録・損傷分析は NTN(株) によって行われたものである。

参考文献

- [Bach-Andersen M 17] Bach-Andersen M, W. O., Rmer-Odgaard B: Deep learning for automated drive train fault detection, *Wind Energy*, Vol. 1, No. 13 (2017)
- [Jiaxing 10] Jiaxing, Y., Takumi, K., and Tetsuya, H.: Vowel recognition based on FLAC acoustic features and subspace classifier, in *Proceedings of International Conference on Signal Processing (ICSP)*, pp. 530–533 (2010)

- [Ogata 16] Ogata, J. and Murakawa, M.: Vibration-Based Anomaly Detection Using FLAC Features for Wind Turbine Condition Monitoring (2016)
- [Purajarjomandlangrudi 14] Purajarjomandlangrudi, A., Nourbakhsh, G., Ghaemmaghami, H., and Tan, A.: Application of anomaly technique in wind turbine bearing fault detection, in *IECON 2014 - 40th Annual Conference of the IEEE Industrial Electronics Society*, pp. 1984–1988 (2014)
- [Sigurdsson 06] Sigurdsson, S., Petersen, K. B., and Lehn-Schiler, T.: Mel frequency cepstral coefficients: An evaluation of robustness of mp3 encoded music, in *Seventh International Conference on Music Information Retrieval (ISMIR)* (2006)
- [Takeuchi 12] Takeuchi, A., Haseba, T., and Ikeda, H.: Application of condition monitoring system for wind turbines, *NTN Technical review*, No. 80, pp. 15–18 (2012)
- [Ye 10] Ye, J., Kobayashi, T., and Higuchi, T.: Audio-based sports highlight detection by fourier local auto-correlations, in *Proceedings of the 11th Annual Conference of the International Speech Communication Association, INTERSPEECH 2010*, pp. 2198–2201 (2010)