

風力発電設備に対する負荷条件に依存しない 異常検知手法の開発を目的とした オートエンコーダベース異常検知モデルの提案と考察

石塚諒一^{†‡} 河本薫[‡]

日立造船株式会社[†] 滋賀大学[‡]

1. 背景と目的

風力発電は風況による設備負荷の変動が大きく、異常検知では負荷変動によるデータの変化と設備異常によるデータの変化を区別することが課題となる。そのため、先行研究[1]では異常検知の対象を特定の負荷条件に限定することで、負荷変動の影響を回避している。

本研究では、風力発電設備の中核部品である増速機を対象に任意の負荷条件で異常検知が可能な手法を提案し、その有効性を実データで検証した。

2. 利用データ

提案手法の評価には、実際の陸上風力発電設備（定格出力：2000kW）の増速機から収集した振動データを利用した。このデータは、負荷条件によらず継続的に収集した振動波形（サンプリング周波数25.6kHz）に、ドメイン知識を持つ技術者が異常度合いのラベルを正常・予兆・異常の3段階で付与したものである。本研究では図1に示す通り、入手したデータを、正常(訓練・評価)・正常(テスト)・予兆(テスト)・異常(テスト)の4つに分割し、後述の教師なし機械学習モデルの評価に用いた。




図1 データの分割方法

3. 提案手法の説明と実装

3.1 特徴量の作成

特徴量の作成は、バンドパスフィルタ処理と短時間フーリエ変換(STFT)により実施した。

バンドパスフィルタ処置では、軸受の異常によるデータの変化を際立たせるため、上限7.2kHz、下限4.2kHzの1次バターワースフィルタにより数kHz帯の振動を強調した。

STFTでは、振動波形をスペクトログラムに変換する。実装は、窓サイズ：2048(0.08秒)、スライドサイズ：512(0.02秒)とし、最終的なスペクトログラムの次元は周波数軸：1025、時間軸：50となった。

3.2 オートエンコーダベースの異常検知モデル

本研究では、オートエンコーダベースの深層学習を利用する。これは、深層学習の表現力により、風力発電設備の多様な正常状態を学習することが期待できるためである。提案手法では、モデルの入力として3.1節で示したスペクトログラム、エンコーダとデコーダに畳み込みニューラルネットワーク(CNN)、異常度としてスペクトログラムの再構成誤差の絶対値の平均を利用する。CNNはスペクトログラムの特徴を画像として捉えるために採用した。本研究では以下の3つの手法を比較する。

オートエンコーダ(AE) AE[2]は、入力データを低次元の潜在変数に射影し、潜在変数から入力データを再構成するモデルである。今回の実装を図2に示す。




図2 AEの実装

変分オートエンコーダ(VAE) VAE[3]はAEの潜在変数を事前分布により正規化する。これには、外挿データを潜在変数に射影する際の挙動を安定させる効果がある。よって、外挿となる異常・予兆時に、負荷変動によるスペクトログラムの変化への追従性能が高まり、設備異常によるデータの変化のみを明確に捉えることが期待できる。実装は潜在変数に関連する箇所以外はAEと共通とした。

AE-Grad AE-Grad[4]は学習済みのVAEを用いた再構成手法である。AE-Gradによる再構成像の特徴は、VAEと比較して解像度が高く、学習データに含まれている特徴のみを再構成することである。よって、負荷変動によるスペクトログラムの変化のみを高い解像度で再構成し、設備異常によるデータの変化を際立たせることが期待できる。

4. 検証結果

再構成結果の比較 入力したスペクトログラムと再構成結果の異常度別の一覧を図3に示す。いずれの手法でも、異常によるスペクトログラムの変化は再構成されない傾向にある。また、図4に負荷条件に

Proposal and Discussion of an Autoencoder-Based Anomaly Detection Method Independent of Load Conditions for Wind Turbine

Ryoichi ISHIZUKA^{†‡} and Kaoru KAWAMOTO[‡]

[†] Hitachi Zosen Corporation: 559-8559, Osaka, Japan

[‡] Department of Data Science, Shiga University 522-8522, Hikone,

よる正常データの変化と VAE の再構成像を示す。図 4 より、モデルは負荷変動によるデータの変化に追従している。




図 3 入力データと各手法の再構成像の比較




図 4 負荷条件による正常データの変化と VAE の再構成像

AUC の比較 各手法の AUC を表 1 に示す。対異常の AUC は、どの手法でも高い。一方で対予兆では、VAE と AE-Grad の AUC が AE よりも高くなった。

表 1 各手法の AUC

	AE	VAE	AE-Grad
対異常	0.997	1.000	0.999
対予兆	0.886	0.917	0.911

5. 考察

AE と VAE の潜在変数を、UMAP[5]により次元削減した結果を図 5 に示す。図 5 より、VAE の潜在変数は正常と予兆で一致しているが、AE では一致していない。これは VAE が予兆データを安定して潜在変数に射影したことを裏付ける。これにより、VAE では予兆データの再構成時に、増速機の異常による変化が生じていない再構成すべきピクセルを、正確に再構成できたため、AUC が高くなったと考えられる。

対予兆の ROC 曲線を図 6 に示す。VAE と AE-Grad

の ROC 曲線を比較すると、VAE は AE-Grad と比べて、低い異常度を示したデータに対して高い識別性能を示した。これは、今回のスペクトログラムでは異常検知に必要な本質的な解像度が低く、VAE の再構成像でデータの特徴を表現できたためと考えられる。

一方で、AE-Grad は VAE と比較して、高い異常度を示したデータに対して高い識別性能を示した。これは、VAE ではデータの外挿性が大きくなると潜在変数の分布が正常データと異なり、再構成すべきピクセルの再構成誤差が大きくなるが、AE-Grad では再構成時に予兆データの外挿性の影響を受けずに、再構成すべきピクセルを再構成できたため、と考えられる。

最後に、本研究で検証した事例は一つであることには留意が必要である。今後は本手法を他の事例にも適用し、今回得た知見の一般性を検証することが必要である。

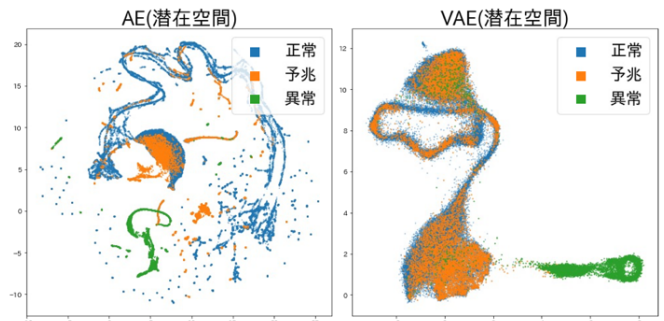


図 5 AE と VAE の潜在空間の比較

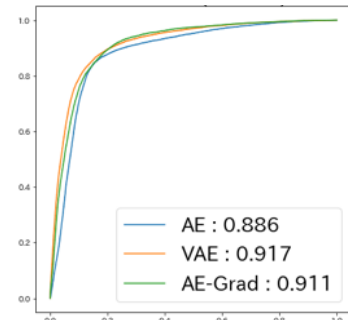


図 6 各手法の ROC 曲線の比較

参考文献

[1] 緒方淳, 村川正宏, 飯田誠. 風力発電スマートメンテナンスのための振動データ解析に基づく状態監視システムの構築. 風力エネルギー利用シンポジウム, Vol. 37, pp. 385-388, 2015.
 [2] G. E. Hinton and R. R. Salakhutdinov. Reducing the dimensionality of data with neural networks. Science, Vol. 313, No.5786, pp. 504-507, 2006.
 [3] Diederik P Kingma and Max Welling. Auto-encoding variational bayes. arXiv:1312.6114, 2013.
 [4] David Dehaene, Oriel Frigo, Sébastien Combexelle, and PierreEline. Iterative energy-based projection on a normal data manifold for anomaly localization. arXiv:2002.03734, 2020.
 [5] Leland McInnes, John Healy, and James Melville. Umap: Uniform manifold approximation and projection for dimension reduction. arXiv preprint arXiv:1802.03426, 2018