

オートエンコーダを用いたリニアモータの異常検知

紙田和喜[†] 上田芳弘[†] 坂本一磨[†] 笠原竹博[‡]

公立小松大学 生産システム科学部[†] 石川県工業試験場[‡]

1. はじめに

近年、工場における生産活動のさらなる効率化のために、IoTやAIの活用が注目されている。中でも、AIの分野の1つである深層学習は、生産活動における主要な課題である人件費の削減やヒューマンエラーの防止にも貢献できるとされており、深層学習の導入による恩恵は大きく期待が集まっている。特に産業装置の異常検知は重要性が高く、様々な試みを実施[1][2]されている。本研究では、産業装置の振動データに着目し、深層学習モデルの1つであるオートエンコーダを用いて、リニアモータの異常振動を検知する手法の実現を目指す。

2. 研究の概要

本研究では、図1の実験装置から取得する振動データから算出する特徴量をオートエンコーダへ入力し、学習・評価を行う。なお、本実験装置では、レーザ光焦点距離の微調整のためにリニアモータがレンズをz軸方向に高速移動(振動)させている。

2.1 実験装置によるデータ取得

本実験において取得する振動データは2種類に分けられる。まず、1つ目が図1のリニアモータ周辺に取り付けられている加速度センサ3軸の内、z軸の加速度データである。本実験においてリニアステージはz軸方向にしか動作しないため、x、y軸方向の加速度データは用いないものとした。2つ目が図2に示すリニアステージの動作履歴を記録したステージ制御ログデータであり、周波数の変化に伴って滑らかな動作をしている。また、学習・評価のために正常な振動データと異常な振動データを取得する必要があるが、異常な振動データについては、リニアステージ部に重量負荷としておもりを取り付けることにより、意図的に異常振動を発生させた。本研究では、図3に示す、入力データのうち、正常動作によって得た振動データを正常データ、重量負荷によって発生させた異常動作によって得た振動

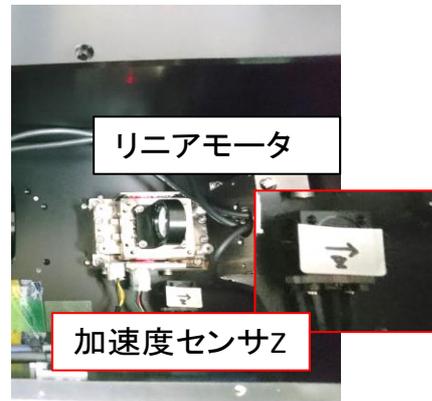


図1 リニアモータ周辺部の外観

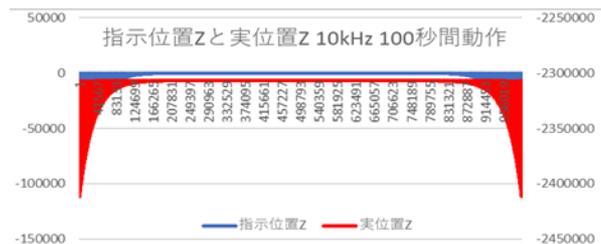


図2 ステージ制御ログデータ

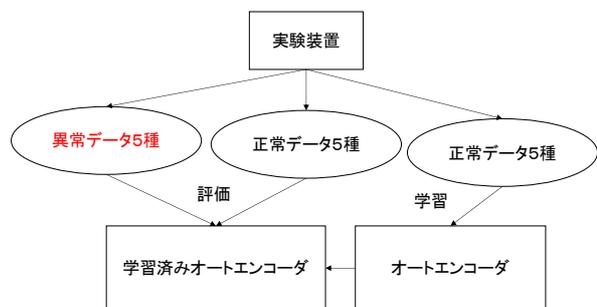


図3 データ解析手順概略

データを異常データとする。

2.2 特徴量算出方法

本研究における特徴量の算出方法として、0.4秒当たり4,096個のデータから136次元の特徴量を算出し、これをオートエンコーダへ入力する。入力の際は、136次元の特徴量のうち、8次元は既存研究[2]に示されている計算式で求められる時間領域特徴量であり、128次元は振動データに高速フーリエ変換を行うことによって得られる周波数領域特徴量である。

Research for Anomaly Detection of Linear Motors Using Autoencoder

[†] Kazuki Kamita, Yoshihiro Ueda and Kazuma Sakamoto
Faculty of Production Systems Engineering and Sciences,
Komatsu University

[‡] Takehiro Kasahara
Industrial Research Institute of Ishikawa

3. 実験概要

本実験では、まず正常データ 10 種と異常データ 5 種類を、ステージ制御データ、加速度データそれぞれについて取得した。

3. 1 実験内容

これらの正常、異常データから算出した特徴量を用いて学習・評価を行っていくが、ここで、データ全域分の特徴量は用いず、100 秒分の区間のデータを 0.4 秒ずつずらしながら全域分別々に解析を行った。オートエンコーダの性質上、複雑な波形の学習は困難な可能性があるため、一部分のみの解析を繰り返し、異常検知のための適切な区間を探索する手法によって解析を行った。ここで、適切な区間とは、正常データの評価結果の上限値が異常データの評価結果の下限値を下回る場所とした。また、重量負荷については 5 段階(リニアモータ全体質量の 1, 3, 5, 7, 9%)で解析を行った。なお、いずれも 5 種の正常データでオートエンコーダを学習し、それぞれ 5 種の正常、異常データで評価を行った(図 3 参照)。

3. 2 結果と考察

本実験の結果を図 4~6 に示す。横軸の値は探索回数であり、前述の通り 100 秒分の区間のデータを 0.4 秒ずつずらしながら解析しているため、計 250 回分(100/0.4)の解析を行っている。縦軸の値は、各区間における、オートエンコーダの誤差、すなわち入力と出力の差の平均を異常スコア値とした。図 4 のとおり 1% の重量負荷をかけた場合では、どの部分でも正常データの上限値が上回っており、検知は困難だと考えられる。3% の重量負荷でも同様な結果となった。一方、図 5 と図 6 のとおり 5% または 9% の重量負荷をかけた場合には、グラフ両端の低周波数領域で、異常下限値が正常上限値を上回っている箇所が多くみられる。7% の重量負荷でも同様な結果となった。このことから、ステージ制御データを用いることで、一定以上の重量負荷をかけた場合に、100~300Hz の低周波数領域において、ある程度高精度な異常検知を行える可能性があるということが分かった。

4. おわりに

今回の解析では、ステージ制御データに関して、低周波数領域で高精度な検知を行える可能性を示した。しかし、高周波数領域や、重量負荷が低い場合の検知は困難なため、学習モデルの改良を検討する。また、加速度センサによるデータの解析を進めている。さらに、リニアモータに重量負荷を取り付けることによって異常振動を発生させたが、この負荷のかけ方を、

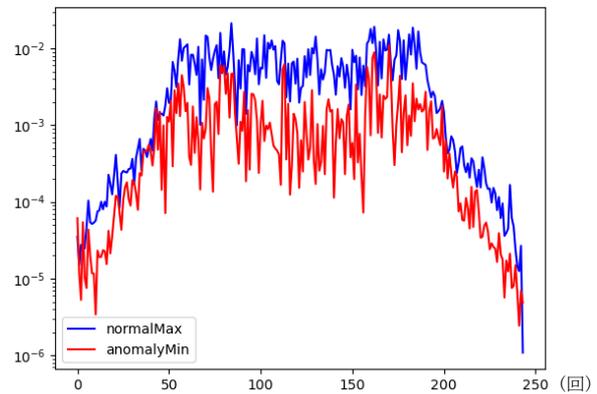


図 4 ステージ制御データ全域探索結果(1%負荷)

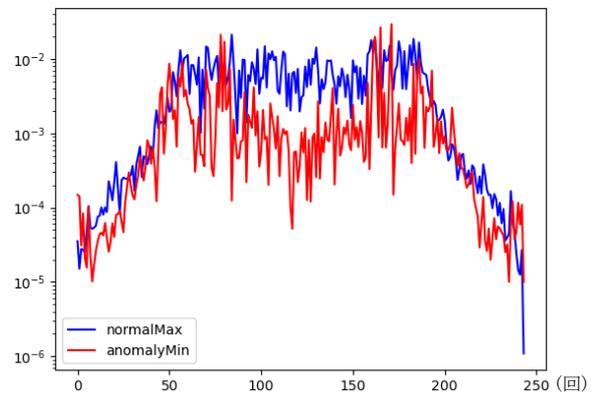


図 5 ステージ制御データ全域探索結果(5%負荷)

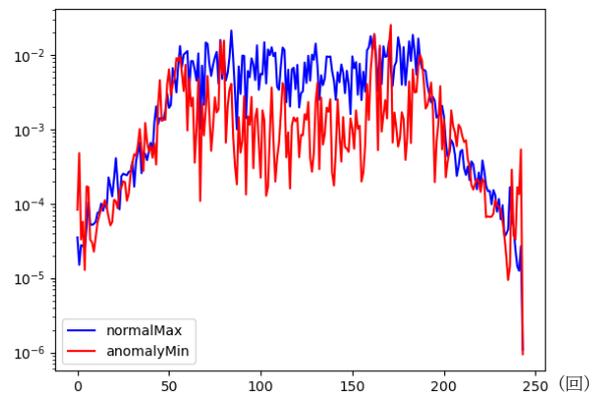


図 6 ステージ制御データ全域探索結果(9%負荷)

軸方向に摩擦抵抗を与えるなど、他の方法による場合にも異常検知の可能性がみられるか、解析を進めていく予定である。

参考文献

- [1]Kasahara, T, Yonezawa, Y, Ueda, Y. and Nambo, H.. Assessing Machine Condition using MLP and VAE-Based Classifiers using Acceleration Sensor Data. *International Conference on Management Science and Engineering Management*, 2019. p. 1-13.
- [2]Guo, L. Gao, H. Huang, H. He, X. and Li, S.. Multifeatures fusion and nonlinear dimension reduction for intelligent bearing condition monitoring. *Shock and Vibration*, 2016, vol. 2016 no. 3, p. 1-10.