

深層学習によるリニアモータにおける異常検知に関する研究

紙田 和喜[†] 上田 芳弘[‡] 坂本 一磨[‡] 笠原 竹博[§]

公立小松大学大学院サステイナブルシステム科学研究科[†]

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

工場では、機械稼働率の向上が重要であるため継続的な設備保全が実施されており、高度な異常検知、異常予知が期待されている。

機械学習を用いた異常検知手法は数多く提案[1][2]されているが、その多くで挙げられている問題として、学習用データに本来必要な異常データ数が不足している点がある。これを解決する手法としてよく用いられる機械学習のモデルが、オートエンコーダ(AE)[3]をはじめとした生成モデルである。この手法は、正常データのみを学習させることにより、評価の際、異常データを入力した時に異常箇所を再現できないため、出力されたデータと入力データに差分が生じる。この差分を異常スコアとして扱い、異常検知を実現する手法である。学習用異常データの不足という問題を解決できるこの手法は、現在でも多くの異常検知タスクで用いられている。

2. 研究の概要

本研究では、既に様々なアプローチがなされている画像による異常検知ではなく、振動異常や摩擦異常を用いた異常検知を試みている。これまでにリニアモータに重量負荷を取り付けて動作させることで発生させた振動を異常振動として扱い、評価に用いた。しかし、実際に起こりうる異常を考えた時、真下方向にのみかかる重量負荷はやや再現性に欠けると考えられたため、今回はリニアステージの動作方向に摩擦抵抗をかけ、その強さを調整しながら学習・評価を行うことにより、検知可能な抵抗値の推定を行っている。

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として、図1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を用いる。リニアステージは周波数の変化に伴って滑らかな動作をしており、グラフの始点、終点付近でその変化がみられる。また、学習・評価のために正常な



図1 ステージ制御ログデータ




図2 実験装置の外観

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、前述したとおり、本研究ではリニアステージの動作方向に摩擦抵抗をかけ、異常振動を発生させた。本研究では、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データを異常データとする。

3. 実験概要

まず予備実験として、リニアステージを動作させ、摩擦力の強さを調整しながら抵抗値データを取得し、摩擦力の変化に対する抵抗値の推移をみる。その後、本実験として同じようにリニアステージを動作させ、次は振動データを取得していく。また、今回用いる実験装置の外観を図2に示す。

3.1 予備実験手順

摩擦抵抗を発生させるためにまずは、マイクロメータとばねを取り付けたセラミックボールを固定し、それに対してリニアステージを摺動させることで、固定したセラミックボールと接触させる。それによって生じた摩擦抵抗をリニアステージに取り付けられたセンサで電圧に変換し、これを抵抗値として記録していく。力の調整は、セラミックボールに取り付けたマイクロメータの変位量、ばね自体の押し付ける力の2つの要素で調整をしながらデータの取得を行う。マイクロメータの値は、13.5mmから2.0mmにかけて、0.5mm刻みで変化させていくが、この内、13.5mmの時、セラミックボールは接触していないため、この時の状態を正常データとして扱い、

Research for Anomaly Detection of Linear Motors Using Autoencoder

[†] Kazuki Kamita,

Graduate School of Sustainable Systems Science, Komatsu University

[‡] Yoshihiro Ueda and Kazuma Sakamoto

Faculty of Production Systems Engineering and Sciences, Komatsu University

[§] Takehiro Kasahara

Industrial Research Institute of Ishikawa

それ以外の変位量は全て異常データとして扱う。

3. 2. 1 本実験

これらの正常，異常データを用いて学習・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。また，リニアモータの動作方法として，周波数を100～500Hzの範囲で変えながら動作させる方法を用いているため，データの区間ごとに周波数が異なる。学習モデルの性質上，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，摩擦抵抗については予備実験時と同様，13.5mm～2.0mmの範囲で，16段階で解析を行った。なお，各変位量5種類ずつ振動データを取得し，その内の正常データ(13.5mm)で学習し，異常データ(13.0mm～2.0mm)で評価を行った(図3参照)。

3. 2. 2 結果

図4と図5は，いずれも各変位量における異常スコア値を記録したものであり，横軸は各変位量(13.5mm～2.0mm)5データずつの学習・評価回数をとっている(16変位量×5データ)。ここで，異常スコア値とは，学習モデルへの入力と出力の差分の平均値を示したものである。また，図の実線部は正常データの異常スコア値を示したものであり，破線部は異常データの異常スコア値を示したものである。これら2つの図はそれぞれ，図4が振動データの140～180Hz帯，図5が260～300Hz帯で取得したもののだが，正常データと異常データそれぞれの異常スコア値に明確な差が生じている後者のみ，異常検知の可能性がみられる。

3. 3 追加実験

これまで，リニアステージの振動データを，生成モデルを介して再生成することにより，異常振動の検知を試みてきたが，追加実験として，予備実験の際に取得した抵抗値データを用いた回帰推定を行う。

手法としては，抵抗値データを元に算出した回帰線と，振動データ及び抵抗値データを学習・評価することにより出力した値をそれぞれ，正解値，推定値としてグラフ上で比較する。また各変位量の5データはいずれも同じ異常データであるため，leave-one-out法により，4データを学習用データ，1データを評価用データとして扱うことで学習・評価を行う。

4. おわりに

本実験について，特定の周波数領域でのみ検知の可能性がみられ，また，摩擦抵抗が大きくなるにつれて，異常スコア値の大きさも，連続

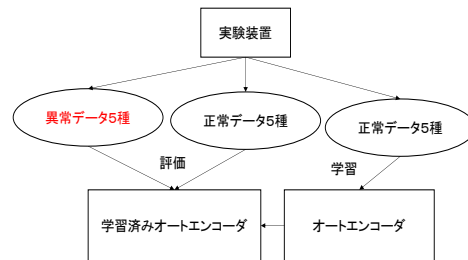


図3 データ解析手順概略




図4 各変位量での異常スコア値(140～180Hz)




図5 各変位量での異常スコア値(260～300Hz)

的な推移がみられた。追加実験に関して，現状は良好な精度が得られていないため，モデル改良による改善を試みる。また，今回再現した異常は非常に単純なもので，現実に起こりうる，より複雑な異常を想定した際に単純なモデルでは学習が困難な可能性がある。そのため，今後はより高度なモデルを用いた学習を試みたい。

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.
- [3]Hinton, GE. And Salakhutdinov, RR.. Reducing the dimensionality of data with neural networks. *Science*, 2006, vol. 313, p. 504-507.