

機械学習を用いたプレス機の異常評価

田口 智之*1 林 宏充*1 桑山 健太*2

Evaluation of Press Machine Anomalies using Machine Learning

Tomoyuki Taguchi, Hiromitsu Hayashi and Kenta Kuwayama

近年、コンピュータの性能向上やクラウドサービス等による膨大な計算リソースを獲得したことから、機械学習等のAI技術の本格的な活用が始まっている。本研究ではプレス機の音を対象とし、プレス機の異常を音から判断して数値化するAIモデルを開発した。開発したAIモデルの有効性を検証するために、プレス機の正常な状態と明確な異常が発生した状態の評価を実施した。その結果、プレス機に異常が発生する前後で異常値の分布に統計的に有意差があったことから、開発したAIモデルの有効性の確認ができた。

1 はじめに

機械から異音が発生する原因の多くは機械及び部品の不良や異常であるが、わずかな音の変化から機械の異常を検知することは、熟練の技術者の経験や勘が頼りであった。しかし、熟練の技術者の退職や労働人口減少により、技術の継承が困難となってきている。そのため、熟練の技術者の知見をAIに学習させることで、機械の異常を数値化し、個人の感覚に依存せず定量的な判断が可能な仕組みを求めるニーズがある。

福岡県の工業統計調査（令和2年度）¹⁾によれば、金属製品製造業は県内製造業の中で食料品に次いで2位の事業所数（706）を占め、出荷額（5,679億円）も輸送機械、食料品、鉄鋼に次ぐ4位である。特に北九州地域では、主要な産業の1つとなっている。その金属製品製造においては、様々な機械加工を原材料に施しており、その中でプレス加工は他の機械加工と比較して生産性が高いとされている。そのため、プレス機の不具合が大きな生産性の低下に直結する。

本研究では、機械学習の一種であるディープラーニング（深層学習）により、プレス機から発生する音を異常値として可視化するAIモデル開発とその評価を行った。AIの性能は学習させるデータに依存するため、機械の様々な状態のデータを計測する必要がある。しかし、工場設備の異常発生は稀であり異常な状態も様々である。そこで、正常な音のみを学習する教師なし学習により異常値を算出するAIモデル開発を行った。

2 研究, 実験方法

2-1 周波数解析

2-1-1 プレス機の録音

プレス機の録音はTASCAM社製DR-70Dを使用した。図1に録音装置の概要を示す。プレス機天井部にはプレス駆動用のモータがあり、センサをモータ台座部に直接固定して録音した。録音はCD品質である、44.1 kHz・16ビットで行った。




図1 録音装置概要

2-1-2 音声の周波数解析

音データはサイズが非常に大きく、コンピュータのリソースが限られていたため、音データをAIに直接学習させることが困難であった。そこで、周波数解析により特徴的な情報を抽出し、その情報を画像化することでデータ量を抑えることとした。

周波数解析は、抽出した一定区間の音データに短時間フーリエ変換（STFT）処理を行った。STFTは音データの区間の一部領域をオーバーラップさせながら窓関数を掛けフーリエ変換を実行するアルゴリズムである。周波数解析にはプログラミング言語の一種であるPythonと、その言語の数値計算ライブラリであるSciPyを使用した。STFTのパラメータを表1に示す。

*1 機械電子研究所

*2 株式会社山本工作所

表1 STFTパラメータ

項目	値
窓関数	カイザー窓 ($\alpha=4$)
ウィンドウサイズ	16384
オーバーラップ数	15360
モード	振幅

2-1-3 周波数解析結果の画像化

プレス機の音の低周波数領域は鋼材をプレスする際のインパクト音が支配的であり、異常音がプレス音に紛れてしまうと考えた。そのため、周波数解析結果の画像化は図2のように、インパクト音を除いた区間の周波数の高いほうから1/8の区間（19.29375 kHz～22.05 kHz）を抽出し正規化することで、グレースケール画像を作成した。作成されたグレースケール画像を図3に示す。




図2 周波数解析結果の画像化




図3 周波数解析結果のグレースケール画像

2-2 AIモデル構築

2-2-1 AIモデルネットワーク

本研究では、教師なし学習の手法であるAutoencoder（自己符号化器）を用いた。Autoencoderとは、ニューラルネットワークの一種であり、入力されたデータを一度圧縮し、重要な特徴量だけを残した後、再度もとの次元に復元処理を行うアルゴリズムである。異常値は、本アルゴリズムにより得られた入出力の差から算出する。

AIモデルの構築および学習にはPythonと、その言語のディープラーニング用のライブラリであるKerasを使用した。AIモデルは、入力層が1層、中間層が13層、出力層が1層の計15層で構成される。入力層と出力層は128（縦）x 128（横）x 1（色）= 16384個である。図4にAIモデルネットワーク全体を示す。




図4 AIモデルネットワーク

2-2-2 AIモデルの学習

AIモデルのネットワークを使用して、正常な音の画像データを学習させた。学習データ数は40000、最適化関数はAdam²⁾、損失関数はSSIM³⁾ (Structural Similarity)、バッチサイズは16、エポック数は100とした。また、画像化データは128 (縦) x 128 (横) にリサイズしたものを入力としている。

ここでSSIMとは、2つの画像の類似性を測定する手法の一種であり、人間が感じる2つの画像の違いを指標化したものである。数式を(1)に示す。

$$SSIM(x, y) = \frac{(2\mu_x\mu_y + c_1)(2\sigma_{xy} + c_2)}{(\mu_x^2 + \mu_y^2 + c_1)(\sigma_x^2 + \sigma_y^2 + c_2)} \quad (1)$$

SSIMは図5の画像内の小領域毎に算出される。 x 、 y は入力画像と出力画像の小領域の各画素を要素とするベクトルである。また、 μ_x 、 μ_y は小領域内の画素値の平均値、 σ_x 、 σ_y は同小領域内の画素値の標準偏差、 σ_{xy} は x と y の共分散、 c_1 、 c_2 は定数であり、一般的な値である $c_1=0.01$ 、 $c_2=0.03$ とした。学習の際にはすべての小領域でSSIMを算出し、その平均値を損失関数として使用した。




図5 SSIMの小領域

2-3 異常値の算出

異常値は学習済みのAIモデルへ入力した画像と出力画像から算出する。まず、入出力された画像の差分の絶対値を取り、一定のしきい値で二値化画像を作成する。次に、全画素数に対する白色画素数の割合で異常値を算出する。今回は、しきい値を画素値の5%である12とした。

3 結果と考察

3-1 構築したAIモデルによる異常値の算出

図6および図7に正常時と異常時の音の入出力画像とその差分および二値化画像を示す。異常データは、モータ台座締結部のボルトが破断した際のデータである。このときの正常時と異常時の音の異常値はそれぞ

れ0.0014、0.6419であり、正常時から外れた程度が大きいほど異常値が大きくなることが確認できた。




図6 正常音の入出力画像とその差分および二値化




図7 異常音の入出力画像とその差分および二値化

3-2 異常値の時系列評価

鋼材をプレスした際に発生するインパクト音をトリガーとして、プレス機の異常値を算出する。異常が発生していない日(2019/12/13)の音データの異常値の時系列グラフを図8に示す。異常が発生していない場合には、終日異常値が0.05未満で推移することが確認できた。

同様に異常が発生していない日(2020/1/20)の音データの異常値の時系列グラフを図9に示す。日中は異常値が0.05未満で推移しているが、18時直前から異常値が上昇する結果が得られた。プレス機の稼働停止前に異常値が上昇する現象は、2020/1/20のみではなく頻発していることが確認された。いずれの場合にも、日中は異常値が0.05未満で推移している。

2020/10/8に実施したプレス機のメンテナンスにて、モータ台座部の4本のボルト全ての破断が確認された。モータ台座部のボルトが破断されたと考えられる期間中の日(2020/9/17)の異常値の時系列グラフを図10に、破断したボルトを図11に示す。ボルトが破断されたと考えられる期間中は、日中の異常値が0.05を大きく超えた数値で推移していることが確認された。この現象は、破断したボルトが交換されるまで続いた。このとき、異常の発生前後の1日間の異常値の分布のp値は $p < 0.001$ となった。p値とは、帰無仮説が正しい場合に、実際に観察された、あるいはそれ以上の2群の差が観察される確率である。今回の結果では、統計的に有意に異常値が変化したといえるため、開発したAIモデルの有効性を確認できた。




図8 正常時の時系列グラフ (2019/12/13)




図9 正常時の時系列グラフ (2020/1/20)




図10 異常時の時系列グラフ (2020/9/17)

3-3 考察

プレス機の稼働停止前に異常値が上昇する際の機械的な異常は判明できなかったが、人が知覚できていない異常が発生している可能性はある。また、メンテナンスによる部品の交換や部品の経年劣化等により機械



図11 破断したボルト

の状態は日々変化しているため、正常な状態も日々変化していると考えられる。そのため、正常な状態であるにもかかわらずAIにその状態を学習できていなかったために、プレス機の稼働停止前に異常値が大きい数値で推移した可能性も考えられる。一度AIモデルを構築した後も正常データを継続的に学習し、AIの性能向上に務める必要がある。

4 まとめ

本研究では、プレス機の音を対象にAutoencoderを用いたプレス機の異常値を算出するAIモデルの開発と、開発したAIモデルの評価を行った。その結果、プレス機に異常が発生した際には継続的に異常値が0.05を超える値で推移したことから、開発したAIモデルの有効性の確認とプレス機の異常の可視化ができた。

5 参考文献

- 1) 福岡県：福岡県 令和2年工業統計調査，福岡県 (2021) (オンライン)，https://ckan.open-governmentdata.org/dataset/401000_kougyoutoukeityousa_r2
- 2) D. P. Kingma and J. L. Ba : Adam: a Method for Stochastic Optimization, ICLR, 2015
- 3) Paul Bergmann, Sindy Lowe, Michael Fauser, David Sattlegger, and Carsten Steger : Improving Unsupervised Defect Segmentation by Applying Structural Similarity to Autoencoders, arXiv:1807.02011(2019)