

## センサーデータを用いた異常検知における複数の機械学習手法の比較

## Comparison of several machine learning methods for anomaly detection using sensor data

児玉 総司<sup>†</sup>      正田 備也<sup>†</sup>  
Satoshi Kodama      Tomonari Masada

## 1. はじめに

産業設備の予知保全のための異常検知においては、様々な機械学習手法が活用されてきた。近年は深層学習の適用も数多く研究されている。たとえば Chalapathy らは過去の異常検知に関する論文を調査し、深層学習が高いパフォーマンスを示すとしている [1]。一方で企業の実業務での利用に際しては、精度とコストのバランスを考慮した仕組みが求められるため、手法の複雑さや計算量と、精度の関係を把握することは重要である。本研究では PHM Data Challenge2015 で使用されたセンサーデータを用いて、様々な機械学習手法による異常検知精度の比較を行った。また将来の予測期間と精度の関係を確認するために、予測期間が異なる場合の精度を比較した。

## 2. PHM Data Challenge 2015

PHM (Prognostics and Health Management) とは、産業設備機器の健全性を維持するための活動や技術を指す。PHM Society は、エンジニアリング分野としての PHM の発展を目的とした非営利団体であり、PHM Data Challenge は、PHM Society の年次大会で毎年開催される、現実の IoT データを使ったコンペティションである。

本研究では 2015 年の PHM Data Challenge のデータを用いた。2015 年のテーマは、発電プラントの空調設備の異常検知である。対象のプラント数は訓練用 33 か所、テスト用 15 か所の合計 48 か所であり、それぞれのプラントごとに空調設備の運転状態を示すセンサーの時系列データ約 50 項目と、5 種類の異常の発生期間を示すデータがある。センサーデータの中には、設備状態の計測値と、設備をコントロールするための指示値とが含まれる。テストデータ 15 プラントの異常のデータのうちの一定割合が隠されて提供され、異常の種類と、異常の開始時刻と終了時刻を予測するコンペティションであった。データ期間は約 3 年、データの時間間隔は約 15 分である。

本コンペの入賞の上位 3 者は深層学習を使っていない。1 位のチームは kNN やランダムフォレストや GBM を組み合わせた手法[2]、2 位のチームは LDE[3]、3 位のチームも決定木をベースとした手法を使っている[4]。その後、本データに深層学習手法の一つである RNN をベースにした seq2seq 型のモデルを適用した研究が行われている[5]。

## 3. 手法の違いによる予測精度の比較

## 3.1 問題設定

まずプラント 1 のトレーニングデータ約 3 年分を用いて、全期間のうち初めの 70% を学習データとし、残りの 30% を

<sup>†</sup> 立教大学大学院 人工知能科学研究科  
Rikkyo University, Graduate School of Artificial Intelligence and Science

テストデータと位置づけ、テストデータ中の異常検知を試みた。当時のコンペティションは 5 種類の異常を区別して予測するものであったが、ここでは異常の種類を区別せず異常が発生しているか否かの 2 値分類を行う。また、評価指標についても当時のコンペティションとは異なり、f1 スコアを用いる。

## 3.2 比較した手法

まず手法による精度の違いを見るために、古典的な機械学習も含めて以下の 6 手法で予測を行った。計算には機械学習ライブラリである scikit-learn を用いた。交差検証によるチューニングで得たパラメータを表 1 に示す。

- ① 多変量正規分布を仮定し、マハラノビスの距離を異常度として判定 (図では「正規分布」と記載)
- ② 確率的勾配降下法 (SGD)
- ③ 非線形のサポートベクターマシン (SVM)
- ④ Linear Discriminant Analysis (LDA)
- ⑤ One-Class SVM (OC-SVM)
- ⑥ 多層パーセプトロン (NN)

表 1 : 各手法の主なパラメータ

No.	パラメータ
①	マハラノビスの距離を異常度とした手法
②	alpha = 1e-05, loss = 'hinge', learning_rate='optimal'
③	kernel='rbf', C=316.227766, gamma=0.0316227766
④	tol = 0.1, solver = 'svd'
⑤	nu=ft 0, kernel='rbf', gamma='auto'
⑥	(128,128,128),'relu',batch=256,max_iter=512,alpha=0.001

## 3.3 結果

6 つの手法の評価結果を図 1 に示す。マハラノビスの距離にもとづいて異常度を計算する手法では、ほとんどの異常を検知できなかった。また SGD と OC-SVM の f1 スコアはそれぞれ 13.22% と 14.84%、LDA が 24.77%、非線形 SVM が 32.24%であった。3 層(128x128x128)の多層パーセプトロンの f1 スコアは 37.22%で、最も良かった。

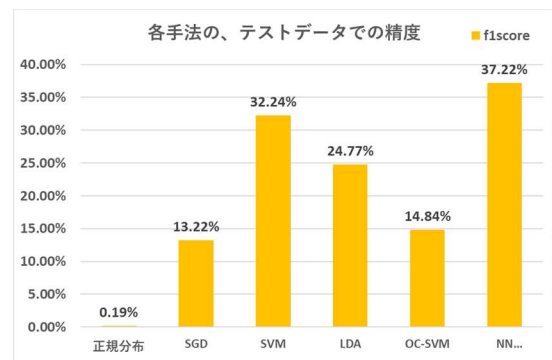


図 1 各手法のテストデータでの精度

以上より、各モデルともパラメータ調整による精度向上の余地はあるものの、同条件で比較した場合には、本データに関しては深層学習を使うほうがより高い予測精度を得られる可能性があることがわかった。

上記の精度を評価するために、本コンペティションで3位になったチームの論文[4]に掲載の、プラント1のデータでランダムフォレストを使った分類結果と比較した。

表2 本コンペ3位入賞者のプラント1での分類結果

Plant #	TP	MC	FP	FN
1	494	2406	10307	272

表2のMCは“異常であるということは正しく判定したが、異常の種類が誤っていた”という意味である。本研究では2値分類にしたので、MCも含めてTP (true positive) であると考え、本表から計算できるf1スコアは約34.5%である。2値分類であること以外にも本研究とは条件の違いがあり単純な比較はできないが、多層パーセプトロンのf1スコアは、おおむね妥当なものと考えた。

## 4. 予測期間の違いによる精度の比較

### 4.1 予測手法

設備を運転している実用場面においては、刻々と送られてくる計測データにもとづいて、一定期間先までの異常有無を予測しつづけたい、ということが多い。このような利用を想定し、一定期間先の予測を繰り返した場合の、予測期間による精度の差を比較した。

予測手法は、Zhang らが[5]で使用したRNNベースのseq2seq型のモデルとした。図2にモデルの概念図を示す。RNN層は2層のGRUで構成し、隠れ層の次元は128とした。試行錯誤の結果、今回は過去3時間の情報を使ってN分先の予測を行う、ということを繰り返した。予測期間Nは15、90、150分の3ケースを行った。各予測ステップでは、現時点までの計測データと前の時点までの異常有無のデータが得られたと考え、これらを利用して、現時点での異常検知を行い、その結果を次の予測ステップで利用する。これをN分先を予測するまで繰り返した。

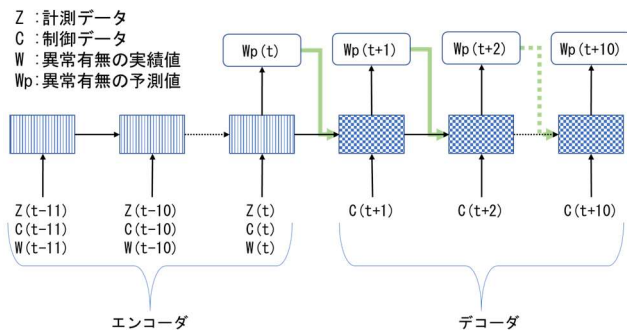


図2 モデルの概念図

## 4.2 結果

上記の方法で予測を行った結果を図3に示す。150分予測の場合の精度は52.08%、90分予測は60.32%、15分予測の場合は84.43%であった。




図3 予測期間別の精度

予測期間が長くなるほど予測精度が低下することがわかった。必要な予測期間はユースケースにより異なり、また、精度変化の傾向はデータによって異なると考えられるため、予測を業務で用いる場合は、採用するモデルの予測期間に応じた精度の差を把握することは重要と考える。

## 5. まとめと今後の課題

6種類の機械学習手法を用いて、コンペティション PHM Data Challenge 2015 の問題設定に近い形で実験を行った。シンプルな深層学習モデルである多層パーセプトロンの精度が最もよいことがわかった。一方で、深層学習はモデルの作成や調整のコストが大きいため、実務においてはまず非線形 SVM などほかの方法を試し、期待精度に達しない場合に深層学習を検討するという方法もある。

また、リアルタイム異常検知という業務での利用を想定し、RNNをベースとするseq2seq型のモデルを使って逐次予測の実験を行った。その結果、予測期間が短いほど高い精度が得られることがわかった。そのため、実務においては、必要とされる予測期間と精度のトレードオフを考慮したモデルづくりが必要であると考えられる。

今後は、ユースケースに応じたモデル選定や予測期間の設定方法を、より形式化することを目指したい。

## 参考文献

- [1] Raghavendra Chalapathy and Sanjay Chawla. Deep Learning for Anomaly Detection: A Survey. arXiv:1901.03407v2 (2019)
- [2] Wei Xiao. A Probabilistic Machine Learning Approach to Detect Industrial Plant Faults: PHM15 Data Challenge. *Annual Conference of The Prognostics and Health Management Society 2015*. (2015)
- [3] Hyunjae Kim, Jong Moon Ha, Jungho Park, Sunuwe Kim, Keunsu Kim, Beom Chan Jang, Hyunseok Oh, and Byeng D. Youn. Fault Log Recovery Using an Incomplete-data-trained FDA Classifier for Failure Diagnosis of Engineered Systems. *Annual Conference of The Prognostics and Health Management Society 2015*. (2015)
- [4] Cong Xie, Donglin Yang, Yixiang Huang, and Donglai Sun. Feature Extraction and Ensemble Decision Tree Classifier in Plant Failure Detection. *Annual Conference of The Prognostics and Health Management Society 2015*. (2015)
- [5] Wenyu Zhang, Devesh K. Jha, Emil Laftchiev, and Daniel Nikovski. Multi-label Prediction in Time Series Data using Deep Neural Networks. arXiv:2001.10098v1 (2020)