

機械学習による生産分野における異常検知システムの開発 -AutoEncoder + LOF モデル-

Development of machine-learning based anomaly detection system for manufacturing -Autoencoder + LOF model-

茨城大学 工学部 知能システム工学科 ○村越智弘 ◎周立波

要 旨

従来のルールベースによる異常検知の限界や、機械学習モデルを構築するときに必要な異常時のデータの少なさを、特徴量抽出などの問題に対する異常検知モデルとして、機械学習（オートエンコーダによる特徴量の自動抽出とLOFによる異常検知）を用いたモデルを提案する。モデルの検証として、擬似的なデータを用いた検証を行い、異常検知の精度から最適なモデルの導出等について検討する。

1. 緒言

昨今、生産分野ではIoT化が進進しつつあり、センサからリアルタイムで取得したデータを利用し、機械学習を用いた異常検知がしやすくなりつつある。そうした中で、従来のルールベースの異常検知の限界から、近年、機械学習などを利用した多くの異常検知の手法が提案されている^[1]。

しかし、そうした多くの異常検知の手法では、得られた時系列データから人の手で特徴量を抽出する必要があるために、リアルタイム性に欠けるという欠点があった。また、実際の生産分野では異常というのは頻繁に起きるものではなく、機械学習モデルを構築するのに必要な教師データとして、十分な数の異常データをそろえるのは困難であるなどの問題もある。

こうした諸問題に対応するため、私は正常データのみで学習したAE(Autoencoder)を用いて、実測データから自動的に抽出した特徴量を使用し、機械学習の手法の一つであるLOF(Local Outlier Factor)により、異常を判定する方法を提案し、その性能を検証した。

2. AE(AutoEncoder)による特徴量抽出

AEは深層学習(ANN)の一種であり、図1に示すように入力層と出力層の数が等しく、また入力 x を出力層の教師データとして使うのが特徴である。学習の結果、出力が入力と一致($\hat{y} = x$)することになる。したがって、AEは自己復元ができる特殊なANNであると言える。

これまでAEは学習過程における勾配消失と過学習の対策に用いられてきたが、最近では次元削減やノイズ除去にも効果が認められるようになった。本研究では、隠れ層には入力層を完全に復元できることに着目し、隠れ層には入力データの特徴全てを含有しているという考えに至った。したがって、数隠れ層の数を最適化すれば、入力データの特徴量が圧縮された形で自動抽出することが可能である。

また、正常データのみで学習することで、正常データは正しく復元出来るが、異常データ（学習されていないデータ）については、正しく復元出来ない。そのため、隠れ層からの出力についても、正常データを入力した場合は、一定範囲に密集し、異常データが入力された場合は、正常データを入力した場合の特徴量とは異なる特徴量が得られるのではと推測できる。

3. LOF(Local Outlier Factor)による異常検知

特徴が類似した正常データは特徴空間内で密集するのに対し、異常データは離れて疎らに存在する。この特性に着目して、図2に示す特徴空間内における入力データPの局所密度とk近傍の平均密度の比によって異常度をスコアリングするLOFが提案されている^[2]。特徴空間内にあるデータ群の任意の点に対して式(1)に従い、周囲のデータ点k個との距離から密度を求め、式(2)に基づき、自身の密度と近傍点k個との密度を比較することで、データの各点に対してLOF値を算出する。こうして、算出されたLOF値は、周囲とデータの密度が等しい場合は1近傍の値となり、密度

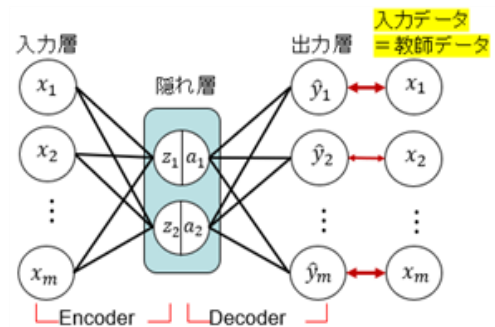


図1 AEアーキテクチャ

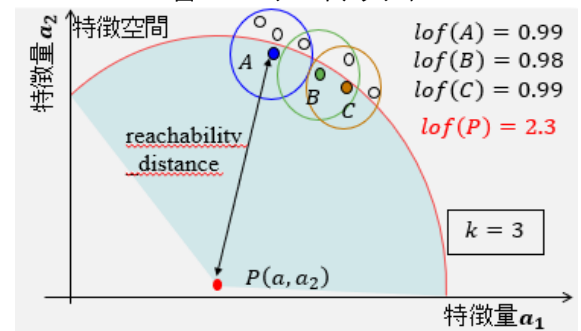


図2 LOF原理

表1 実施条件

	項目	値
使用データ	正常データ	$\sin(2\pi t + \phi)$ ($0 \leq \phi \leq 2\pi$)
	異常データ	$\sin(2\pi t)$ $+N(0,1)$
AE学習条件	訓練・検証エポック	270:30:00
	活性化関数	300
LOF検証条件	オプティマイザ	tanh
	ノード数 [入力層, 中間層, 出力層]	Adam
LOF検証条件	訓練データ	[32, 2, 32]
	テストデータ	1000セット
	近傍数(k)	1000セット
	正常:異常	21
		9:01

が低い。つまり、他のデータ点との距離が離れているほど、大きな値となる。

$$lrd_k(P) = 1 / \left(\frac{\sum_{A \in N_k(P)} reachability_distance_k(P, A)}{k} \right) \quad (1)$$

$$lof_k(P) = \frac{1}{k} \sum_{A \in N_k(P)} \frac{lrd(A)}{lrd(P)} \quad (2)$$

本研究では、AE の隠れ層より抽出した特徴量(a_1, a_2)に対して LOF を適用し、式 (2) で得られる LOF 値を使って異常度を定量化する。

4. 検証結果

4.1 擬似的なデータに対する検証結果

まず、擬似的に生成した正弦波 $x = \sin(2\pi ft + \phi)$ を正常データとし、それに正規乱数 ($\mu = 0, \sigma = 1$) を加えたものを異常データとする。AE の学習過程においては位相のみを $0 \leq \phi < 2\pi$ に変化させた正常データ 1000 セットを用いて学習した。これにより、正常データは完全に復元できるが、正常と異なるデータが入力された時には、完全に復元できない。次に、異常データとして正常データに平均0標準偏差1の乱数をノイズとして加えたデータを作成し、検証用として正常データと異常データの比が 9 : 1 で混合された 1000 セットのデータを用意した。その他の条件は表 1 にまとめた。

AE より抽出した特徴空間内で、LOF(k=21)で異常検知を行い^[3]、算出された LOF 値のヒストグラムを図 3 に示す。青が正常データの LOF 値の分布を、赤が異常データの LOF 値の分布を示している。図 3 からは、正常データの LOF 値が 1 近傍に密集する一方で、異常データの LOF 値は 1~10 程度まで幅広く分布していることが見て取れる。また、このときの閾値となる LOF 値の値は 1.008 となった。結果としては、正常データの内 2 点を、異常データの内 5 点を誤答したが、それ以外については、すべて正しく判別できた。

また、図 4 は近傍数 k による本提案モデルの判別性能を示す。このグラフからは、近傍数 k が 20~30 程度の時、正解率/適合率/再現率がともに 0.98 程度と、高いことが分かる。

4.2 実測データに対する検証結果

次に、実測したモータ動力の出力波形を用いた場合の検証結果を示す。図 5 (a) には、無負荷時の動力波形とフーリエ変換の結果、(b) には 10% の負荷を加えた時の動力出力波形とフーリエ変換結果を示す。このように時間ドメインおよび周波数ドメインのいずれにおいても、見た目では両者の差異はほとんど判別できない。

そこで、任意に採取した (位相が異なる) 無負荷時の動力波形 2500 セットを正常データとして、使って AE を学習させ、続いて 9 : 1 の割合で構成した無負荷時と負荷時のデータ 2000 セットを入力して、LOF による異常検知 (判別) を行なった。

図 6 は、近傍数 k を変化させたときの適合率、正解率、再現率の推移を示す。このグラフからは、 $k=500, 2300$ 前後の時、適合率が 1.0、正解率、再現率が共に 0.9 前後と最も精度が良いことが分かる。

5. まとめ

- 1) AE と LOF を組み合わせて、入力データから特徴量を自動で抽出し、異常検知を行う、モデルを開発した。
- 2) このモデルは擬似的なデータ (人工的に生成した正弦波) や実測データに対して高い精度で異常を検知した。
- 3) 擬似的なデータと実測データに対して、正解率、再現率、適合率などを最適にする近傍数 k を求めた。

参考文献

[1] 福井健一, Python と実例で学ぶ機械学習 識別・予測・異常検知, オーム社, 2018
 [2] M. M. Breuing, et al.; Int. Conf. On Management of Data, 2000.
 [3] sklearn.neighbors.LocalOutlierFactor—scikit-learn 0.23.1 documentation (<https://scikitlearn.org/stable/modules/generated/sklearn.neighbors.LocalOutlierFactor.html>)

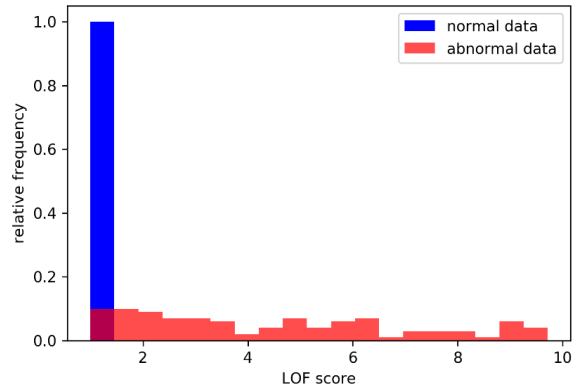


図 3 LOF 値ヒストグラム




図 4 近傍数 k と正解率, 適合率, 再現率




図 5 (a) モータ動力の出力波形とフーリエ変換 (無負荷)




図 5 (b) モータ動力の出力波形とフーリエ変換 (10%負荷)




図 6 実測データでの近傍数 k と正解率, 適合率, 再現率