

# 異常検知に関する機械学習手法の利用方法の提案と評価 - オートエンコーダによる次元削減を用いたクラスタリング -

住谷 浩一<sup>1</sup> 本田 澄<sup>2</sup>

**概要:** 機械学習や深層学習を用いて異常の検知を行うシステムを構築する場合、訓練データからシステムを最適化する帰納的なプログラミングが必要になる。問題は、性能が訓練データの量と質に影響されることであるが、性能を担保する網羅的な訓練データを準備することは容易ではない。本報告では、異常検知の適用事例から現在のプログラミング構造の特徴をまとめた上で、一般工程で多く取得されている、教師ラベルがない時系列信号に対しても適用可能とすることで量と質の問題を解決する状態検知のワークフローを提案する。具体的には、時系列信号を直接オートエンコーダの入力として次元削減された特徴量を生成し、k-meansによってクラスタリングを行うことにより工程の状態を層別するフローと、その結果をドメイン特徴量の指標で評価するフローから構成される。プロトタイプをグラスウール製造工程の回転機械に設置された一軸加速度センサに対し実装し、提案方法の有効性と妥当性を評価する。

**キーワード:** 機械学習工学, オートエンコーダ, 異常検知, 外れ値検知, クラスタリング, 加速度センサ, 帰納的プログラミング, 説明性

## Proposal of Machine Learning Workflow for Anomaly Detection - Clustering by Autoencoder Dimensionality Reduction -

KOICHI SUMIYA<sup>†1</sup> KIYOSHI HONDA<sup>†2</sup>

**Abstract:** In structuring a system that detects anomalies using machine learning or deep learning, inductive programming to optimize the system from training data is required. Performance is dependent on the quantity and quality of training data, but the preparation of comprehensive training data is not easy. This paper summarizes the programming structure for anomaly detection, then proposes the condition monitoring workflow for time-series data that are typically not labeled and intricately mixed normal with normal or vice versa. The acceleration signals are directly fed into the Convolutional Autoencoder to generate the dimensionality reduced features, and clustered by k-means. The prototype is implemented on a uniaxial accelerometer of rotating machinery in the glass wool manufacturing process, and validated by the results of domain knowledge.

**Keywords:** MLSE, Machine Learning Systems Engineering, Deep learning, Autoencoder, Anomaly detection, Outlier detection, Clustering, Inductive programming, Accelerometer, Explainable

### 1. はじめに

近年、機械学習や深層学習を用いて異常の検知を行おうとする試みが多く行われているが、多様な工程の時系列信号に合わせて特徴量を設計し、異常検知・予測を実用化することは容易ではない。

製造工程においては、正常であることを前提として運転されているため、教師あり学習に必要な異常データの収集が現実的でないという問題がある。網羅的なデータ収集が難しい場合、正常なデータからの逸脱を異常とみなす教師なし学習によるシステムが利用されているが、一方で、教師なし学習には絶対的な評価指標がないため、仮に正常とは区別された場合であっても、そのことが直ちに異常であるとは限らないという閾値の問題がある[1][2][3]。これに加えて、プロセス産業で機械学習応用システムを難しくしているのが、工程内の種々の変動が、観測されたデ

ータに合成されてしまうことであり、それにより、そもそも正常と異常の境界を正しくアノテーションすること自体が容易ではないことである[4][5]。正常に生産されている場合であっても、設備の経時劣化による変動以外に、工程の設定条件そのものによる変動、原材料や周囲環境の変動など、一概に異常とは言えない変動が含まれる。これに対応して精度と汎化性能を同時に上げるには、監視対象に依らない本質的な特徴量を抽出して利用するか[6]、あるいは、現在の観測値の主要因を特定して、要因別に特徴量を決定する分類問題を同時に解くかであるが、要因ごとにアノテーションされた訓練データを準備することは、さらに容易ではない。

一般的に、機械学習の精度と汎化性能は特徴量によって決まるが、高性能な特徴量が抽出できるかどうかは、訓練データの網羅性とアノテーションの精度に依存してしまう。これらの、データの量と質に連鎖すると考えられる課題の特徴として、帰納的プログラミングの構造があげられ、その開発手法の整備のため機械学習工学の必要性が提唱されている[7][8][9][10][11]。

<sup>1</sup> マグ・イゾバール株式会社  
MAG-ISOVER K.K.

<sup>2</sup> 大阪工業大学 情報科学部情報システム学科  
Osaka Institute of Technology

本研究では、時系列信号を用いた異常検知、および関連する研究のプログラミング構造を、特徴量生成の観点から分類したうえで、アノテーションを必要としない状態検知のためのワークフローを提案することで、網羅的なデータ収集と評価指標という量と質の課題も合わせて解決を試みる。さらに、プロトタイプを構成し、グラスウール製造工程の回転機械に設置された一軸加速度センサに対し実装して、提案方法の有効性と妥当性を評価する。

## 2. 関連研究

### 2.1 特徴量設計を行う方法

最も基本的なフローであり、機械学習の手法は使用するものの、訓練データの仕様、つまり要求仕様がドメイン知識の仮説という形で提供されると考えれば演繹的プログラミングに近いと言える。あらかじめ、前処理も含めてドメイン知識に合わせたモデルの仮説が存在し、仮説に合わせた特徴量を設計してから取得すべきデータセットの構造を決定する。得られたデータセットから機械学習などを利用して探索的な計算を行った上で、仮説を最も良く説明できる特徴量を選択または合成する。さらに、その特徴量の規則性をモデル化することによって未知の応答を予測する。深層学習を含まない。

栗原らは、自動車の多様な信号に対し、平均値など特定の領域知識に依存しない普遍的な特徴量を使用し、先に異常の種類を特定した上で、人工的に発生させた異常を Random Forest に学習させることで、教師あり学習の異常値検出を行った[12]。坂本らは、プレス機械に設置した加速度センサの信号から Fast Fourier Transform によって周波数領域の特徴量を設計し、正常値のみを One-Class SVM に学習させることで、教師あり学習の外れ値検出を考察した[13]。広瀬らは、溶接ロボットに対して加速度センサのみを使用して一般的な振動特徴量を設計し、特定の異常の発生前後を異常と正常にアノテーションすることで Tree 系に学習させて、教師あり学習の異常検知を行った[14]。

特定の異常に限定して収集するか、人工的に発生させた異常データを用いることで、局所的な教師あり学習を可能としている。仮説に基づく理論式または経験式が明確である場合は、特徴量の設計に従った質の高い訓練データが得られ、モデルは早期に高い適合性を有する。また、推論の結果に対して高い説明性がある。一方で、抽出された特徴量は外乱に弱く、精度と汎化性能が相反する。精度を上げるため過剰な前処理を行うと局所モデルになり、閾値の調整などでモデル別に対応する必要がある。

### 2.2 特徴量設計に加えて深層学習を行う方法

2.1 の特徴量設計を行う方法に加え、そこから得られた多次元の説明変数を深層学習に学習させる手法である。

長谷川らは、汎化性能を上げる目的で、監視対象機器以外から取得した異常データからのメルフィルタバンク出力

を特徴量として学習させるディープニューラルネットワークとそのボトルネック特徴量を混合ガウスモデル (GMM) に学習させるタンデム型、および異常データがない場合のために、正常時のフーリエ局所自己相関特徴量をオートエンコーダの入力として学習させ、ボトルネック特徴量を GMM に学習させるタンデム型により、異常検知システムの汎化性能を向上させた[6]。朝日らは、加速度信号のパワースペクトルを特徴量として、正常値のみを学習させる再帰型オートエンコーダと、そのボトルネック特徴量を GMM に学習させ異常度合いを計算することで、機械設備劣化による故障を予測した[15]。郭家寧らは、地震計内の三軸加速度センサデータを用いて、フーリエ変換によって正常時の周波数領域の特徴量を訓練データとして抽出し、正常値のみをオートエンコーダによって学習させることで、復元誤差による異常検知を行った[16]。

初期状態または通常運転状態を正常と定義し、正常値からの外れ度合いで異常を検知すること、または、対象とは別の機器で発生した異常データも利用することで、網羅的なデータ収集を回避した教師あり学習を可能としている。相対的な異常度合いの計算が可能であるが、絶対的な異常の判定には閾値の設定が必要である。深層学習によって抽出された特徴量に、絶対的な基準を持たせるための明確な説明は難しい。ドメイン知識による特徴量で説明性を持たせながら、深層学習によって汎化性能と精度を改善させようとする試みが多い。

### 2.3 特徴量設計を行わずモデル化する方法

ドメイン知識による特徴量設計を行わず、訓練データから深層学習によって特徴量を抽出し、モデル化するフローである。

Hinton らは、2次元の画像に対して Autoencoder によって次元削減した特徴量を抽出し、Principal Components Analysis と比較してより有効性があることを示した[17]。櫻田らは、正規化した時系列データを Autoencoder によって次元削減し、再構成誤差による異常検知を行った[18]。Munir らは、ラベルなしの時系列信号を直接入力した Convolutional Neural Network (CNN) 予測器と、実際の値との比較によって異常検知を行う deep learning-based anomaly detection approach (DeepAnT) を提唱した[19]。Mathilde らは、2次元の画像に対し、CNN で削減した特徴量にクラスタリングで疑似ラベルを付与してクラス分類の教師ラベルとする Deep Clustering 手法で大量の画像の分類を行った[20]。Si Lu らは、2次元画像の次元削減に Autoencoder を使用し、ボトルネック特徴量を k-means などによってクラスタリングする、Deep Autoencoder-based Clustering の手法を提案している[21]。

2.2 と同じ様に、初期状態または通常運転状態を正常と定義し、正常値からの外れ度合いで異常を検知することで、網羅的なデータ収集を回避した教師なし学習を可能として

いるが、訓練データのまま直接入力可能であるところが異なる。非線形なデータ分布に対応可能である反面、精度と汎化性能は訓練データに依存し、性能を上げるためには大量で質の良い教師データが必要になる、完全に帰納的なプログラミングである。説明性のない完全なブラックボックスモデルであるため、局所最適解かどうか判断できず、外挿の信頼性は担保できない。異常の判定には閾値の設定が必要であることに変わりはない。

### 3. 異常検知手法の適用フローの提案

関連研究から考えられる包括的なフローを Fig. 1 に提案する。多様な時系列信号を直接使用するために、特徴量設計を必要としない深層学習法を基本とする 1)。一般的な製造工程で、多量に取得されているデータをアノテーションなしで使用可能とすることで、訓練データの量を確保する。一方で、異常の判断には評価指標としての閾値の設定が必要になるが、深層学習だけでは、得られた特徴量の説明性がなく、ドメインの評価指標をそのまま閾値に適用できない。このため、ドメインの特徴量で評価する機械学習法を 2) に追加して、深層学習の結果と検証することで質の向上を狙う。また、継続した検証により、設備固有のデータ範囲が明らかになり、異常状態から区別された正常状態の評価指標ができることで、網羅的なデータ収集を回避できることを期待している。

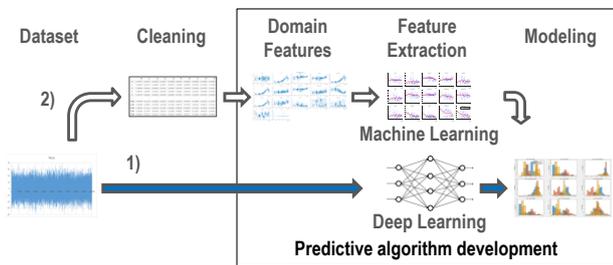


Fig. 1 The outline of the proposed workflow for anomaly detection using machine learning or deep learning of time series data.

### 4. 適用フローの詳細

Fig. 2 に提案するフローの詳細を示す。1 層目が主フローで、深層学習手法の Convolutional Autoencoder (CAE) を使用した Deep Autoencoder-based Clustering を採用した。教師なしの深層学習により、信号から直接入力可能とし、クラスタリングを基本手法とすることで、アノテーションを含む、多変量の前処理の煩雑さを不要としている。具体的には、入力された時系列信号に対し、時間軸方向の畳み込みだけを指定することによって、画像と同様に次元削減されたボトルネック特徴量を抽出する CAE。得られたボトルネック特徴量を、説明可能な次元まで削減する 2 次 CNN。その 2 次 CNN で得られた特徴量を学習させる k-means から構成されるタンデム型のフローである。

実際の工程で取得される信号の多くは、幾つかの要因の結果として合成されており、詳細を解析して正常と異常の区別を正確にアノテーションする時間的余裕のない場合が多い。例えば、回転機械の加速度信号は、定回転数制御の場合においては、負荷となる原材料の特性、ベアリングの劣化、外気温などによって変化するため、正常環境を設定して学習させるとしても、精度を上げようとして条件を細かく設定すると局所的になり、汎化性能を上げようとして条件を広く設定すると異常を見逃すという状態になる[6]。これに対応しつつ、訓練データの全体像が見える特徴量を取り出せるように、クラスタリングとして構成しており、この層を単独でも運用可能である。

2 層目は、1 層目の検証および妥当性を評価するフローである。ドメイン知識から設計された特徴量を学習させ、仮の教師ラベルを作成する k-means フロー、そして、双方から得たラベルから正規化相互情報量 Normalized Mutual Information (NMI) を計算する構成である。ドメイン特徴量との比較によって 1 層目の特徴量抽出が正しいことの検証を、また、NMI を最大化させるように CAE のハイパーパラメータを学習させることで、ドメイン特徴量類似のクラスタリング結果となり、教師なし学習の課題である評価指標の妥当性を、ドメインの閾値として確認できることを期待している。

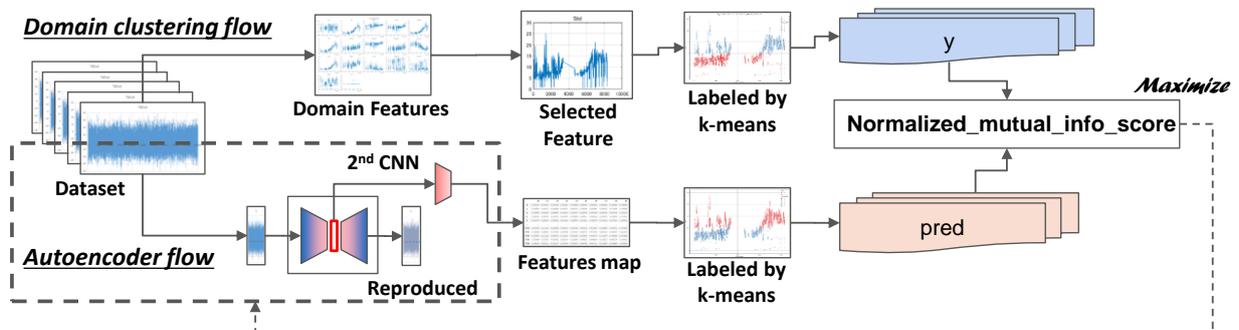


Fig. 2 The block diagram of the proposed condition monitoring flow. It is composed of domain and Autoencoder based clustering separately, and could be trained to maximize a normalized mutual information score of two outputs.

クラスタリングは、非階層として一般的な k-means を使用した。

#### 4.1 CAE と 2 次 CNN の構造

Fig. 3 に実験に使用した CAE と 2 次 CNN の構造を示す。この部分で、入力された信号が、潜在変数空間において異常度に応じた特徴量に次元削減されることを期待している。CAE への入力は、加速度センサから取得された生のデータになる。加速度信号は 1 次元であるので、カーネルも 1 次元であるが、2 次元の CNN を利用するため、以下では(カーネル数, データ点数)の様に表現する。Encoder 部では、(1, 10000)次元の入力加速度信号に対して、16 カーネルで 5 層の畳み込み層と LeakyReLU(Alpha=0.1)を使用して、(16, 313)次元のボトルネック特徴量まで圧縮する。Decoder 部では、同じ層数の逆畳み込み層と LeakyReLU を使用し、入力と復元の二乗誤差が最小になるようにボトルネック特徴量を最適化する。

特徴量を同時に学習するクラスタリングでは、階層が 1 つに集約されるという問題が指摘されており [20], これを回避する手段として、CAE 上で目標次元まで削減せず分布が残るように、ボトルネック次元数を 313 にとどめる。さらに、ボトルネック特徴量を直感的に説明可能な次元まで削減するため、この(16, 313)次元の特徴量に対して、5 層の畳み込み層と LeakyReLU を持つ 2 次 CNN を追加して 10 次元まで削減している。今回の 2 次 CNN は損失関数を持たずに一方向に次元削減するだけである。最後の Affine で 2 次元構造を 1 次元に戻している。

#### 4.2 評価用ドメイン特徴量

1 層目の CAE のクラスタリング結果の評価用として使用されるドメイン特徴量を選定する。選定されたドメイン特徴量のクラスタリングを 2 層目で行い、その結果との対比により 1 層目の評価を行う。ドメイン特徴量の選定には、汎化性能を持たせるため、振動ドメインにおいて代表的な

時間、周波数領域の特徴量を使用した(Table 1)。

Table 1 General Features in Vibration Engineering domain considered by proposed method.

特徴量記号(式)	意味
Mean	平均値
Std	標準偏差
Skewness	歪度、分布の非対称性を示す指標
Kurtosis	尖度、分布の鋭さを示す指標
Peak2Peak	信号の最大値と最小値の差
RMS (root-mean square)	実効値
Crest Factor (Max/RMS)	波高率=ピーク値/実効値
Shape Factor (RMS/Mean)	波形率=実効値/平均値
Impulse Factor (Max/Mean(abs))	インパルス係数
Margin Factor (Max/Mean(abs)^2)	マージン係数
Energy	エネルギー (信号の二乗和)
SKMean	スペクトル尖度の平均値
SKStd	スペクトル尖度の標準偏差
SKSkewness	スペクトル尖度の歪度
SKKurtosis	スペクトル尖度の尖度
FFT Max	スペクトルの局所的最大値
FFT fl	スペクトルの局所的最大値の周波数

この中で、特徴量と設備の使用時間との相関が最も高いものを、評価用のドメイン特徴量として 1 つ選択する。代表的な特徴量の計算式は以下の通り。

$$Std[x] = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \mu)^2}, \quad \mu = \frac{1}{n} \sum_{i=1}^n x_i \quad \dots (1)$$

$$RMS[x] = \sqrt{\frac{1}{n} \sum_{i=1}^n x_i^2} \quad \dots (2)$$

$$Energy[x] = \sum_{i=1}^n x_i^2 \quad \dots (3)$$

#### 4.3 NMI による評価

CAE のクラスタリングの評価指標として、ドメイン特徴量のクラスタリング結果との NMI を用いる。NMI は MI のスコアを 0 から 1 の間になるように正規化したもので、1 が完全な一致を示す。クラスターの順序およびラベルの順序によって、スコアは変わらない。計算は算術平均を用

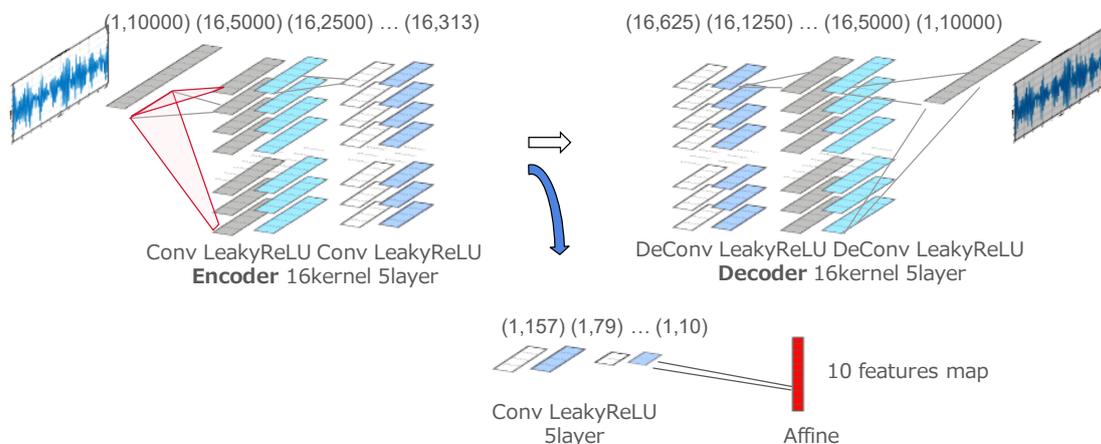


Fig. 3 The architecture of proposed dimensionality reduction using first-stage Convolutional Autoencoder, followed by second-stage CNN. The first-stage extracts the bottleneck features that restore the input signal, and the second-stage additionally reduces the dimensionality of bottleneck features.

いた[22].

1層目のCAEのボトルネック特徴量が、潜在変数空間において異常度に応じた分布の方向に学習されない場合でも、CAE側のハイパーパラメータ学習にNMIの最大化を用いることで、CAEのボトルネック特徴量が、選択したドメイン特徴量の潜在変数空間における分布に一致するように学習されることを期待している。

## 5. 適用結果

プロトタイプをグラスウール製造工程の回転機械に設置された一軸加速度センサに適用し、有効性と妥当性を検証した。検知目標は、使用時間に対する設備の状態とした。クラスタリング数は、異常か正常かの判断指標とするために最低限必要な2階層を基準にして検討し、次に3階層に拡張した場合の例を提示する。

### 5.1 センサおよび信号の詳細

測定仕様とデータの構成をTable 2に示す。1軸の加速度センサを、機械装置の回転軸中心に向かって垂直になるように設置し、合計で5台の機械から信号を収集した。回転軸は鉛直方向となるため、加速度センサは水平方向にネジ止めされている。機械構成の都合上、加速度センサは回転軸中心よりやや離れた機械装置の外装部に設置している。円すいころ軸受を有する回転機械であり、通常約2000回転付近で運転される。円すいころ軸受の転動体の損傷を詳細に検知するためには、回転数×転動体の数×6を上限としたサンプリング周波数288KHz程度が必要とされるが[23]、今回はセンサの仕様から50KHzに限定された。回転軸振動および円すいころ軸受の内輪外輪に関する損傷に関しては十分観測範囲内と考える。

Table 2 Experimental condition of acceleration measurement.

Sensor type	ifm VSA001 Accelerometer
Sampling frequency	50 KHz
Measured time	2 sec
Num. of data points	100,000 points/measurement
Cycle	60 minutes
Observation period	0~9000 hours
Num. of samples (Num. of machinery)	5 rotating machinery (S/N 1,2,3,6,7)
Sample size	7737 total (No.1=1366, No.2=2311, No.3=1833, No.6=1149, No.7=1078)

信号は、1時間に1回、2秒間取得した。5台の機械のうち1台は予備機とし、状態の悪くなった機械と入れ替えて整備しながら運転した。一旦整備された機体の使用時間はゼロにリセットされる。使用開始から整備までの期間はおおよそ約1年間であり、その間、異常が観測されなければ連続して使用される。整備はオーバーホールであるが、すべての消耗部品が更新されるわけではない。なお、今回は

回転機械1台を1群としてみなし標本数を5台とし、標本サイズをそれぞれの測定数として記載している。また、実生産中のデータのみを選択し、運転停止中の低い信号レベルは標本から除外するように考慮している。

### 5.2 評価用ドメイン特徴量の選定

CAEによるクラスタリングの結果を評価するためのドメイン特徴量を選定する。Table 1に示した時間領域および周波数領域の特徴量を計算し、その変化を、使用時間を横軸として表示した(Fig. 4)。今回は、代表的な特徴量を、評価指標の一つとして選択するだけなので、特徴量の設計で通常行われる移動平均、欠損値補完などの前処理は行っていない。

Fig. 4の特徴量の中では、Std, Peak2Peak, RMS, Energyが、使用時間と共に増加傾向にある。相関係数は、Std, Peak2Peak, RMSが0.54であり、Energyが0.52であった。全体的に低いが、これは外れ値などの前処理を行っていないことによると思われる。ドメイン知識より、ベアリングの状態悪化に伴い、特定の周波数領域の振動が大きくなることは知られており、加速度信号の標準偏差(Std)は、一般的な状態把握の一つの指標として用いられているので、Stdを特徴量として選択した。

Fig. 4のStdを拡大し、機体番号別に5種類に色分け表示したものをFig. 5に示す。今回の実験データの特徴を見ると、全体として、使用時間が長くなるにつれてStdが増加し、6500時間以降は高止まりする傾向がある。一方で、3000時間以下においては、正常と考えられるStdの低い部分と、幾つかの異常と思われるStdの急激な上昇が、正常から窓を開けて観測されている。3000時間付近ではStdの連続した上昇がみられ、6000時間付近と似た形状となっている。

### 5.3 2クラスタリング結果の比較

Stdをk-meansによって2クラスタリングした結果をFig. 6に示す。これはStdそのものをクラスタリングした結果であるので、Stdの大小によって2つのクラスに明確に区分されている。6500時間を超える部分は、主としてStdの高い部分に区分されている。また、3500時間以下の部分については、窓の部分境界にして、Stdによって2つに層別された。境界が10 m/s<sup>2</sup>付近になっているのは、設備による固有値と考えられる。これを評価用の仮の教師ラベルとする。

Fig. 7にCAEによって抽出した10次元の特徴量を、k-meansによって2クラスタリングした結果を示す。60Epochでの結果で、縦軸は同じStdを用いている。Fig. 6とFig. 7のNMIは0.77である。CAE側は、7000時間以下で、やや境界が入り組んでいる部分があるが、両方とも10 m/s<sup>2</sup>付近で層別されている。CAEの計算ではメモリ不足のためバッチサイズを128まで下げている。また、標本は時間軸に対して2秒100000点の測定データであるが、計算コストを下げるため、各標本の10000点目を開始時刻にして

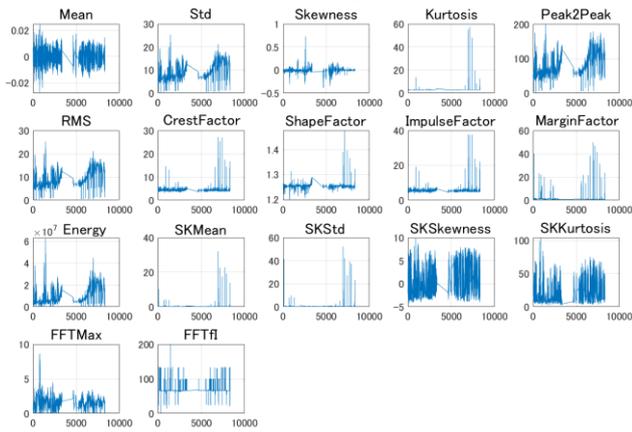


Fig. 4 Result of calculation for Time and Frequency domain features versus Rotation machinery running time period. Line plot for vertical axis gives each feature.

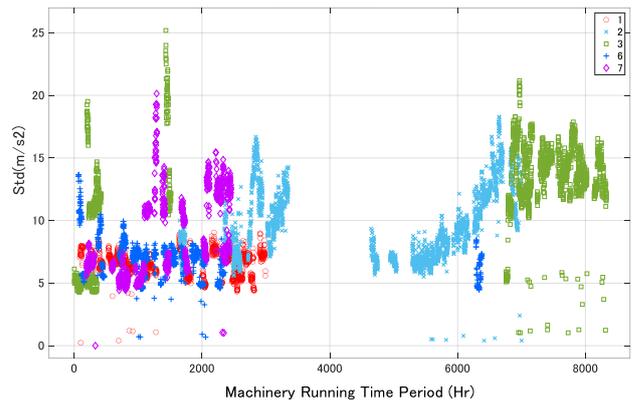


Fig. 5 Scatter plot for Standard Deviation (Std) versus Rotation machinery running time period, machine serial number is indicated by color. A domain feature Std that is highly correlated with running time period is selected to make a pseudo-label.

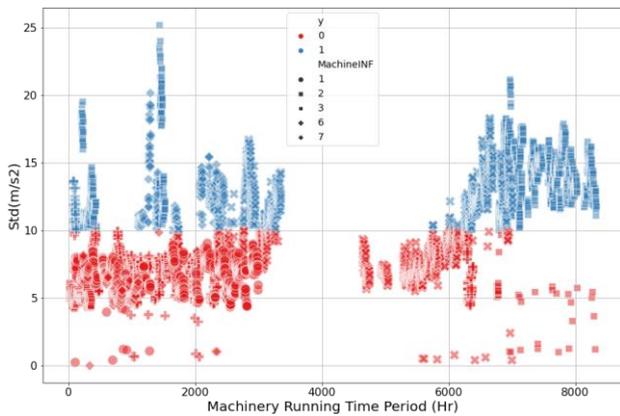


Fig. 6 Two levels clustering by k-means for domain feature, indicated by color. Machinery S/N is indicated by marker type. Scatter plot for Standard Deviation (Std) versus Rotation machinery running time period.

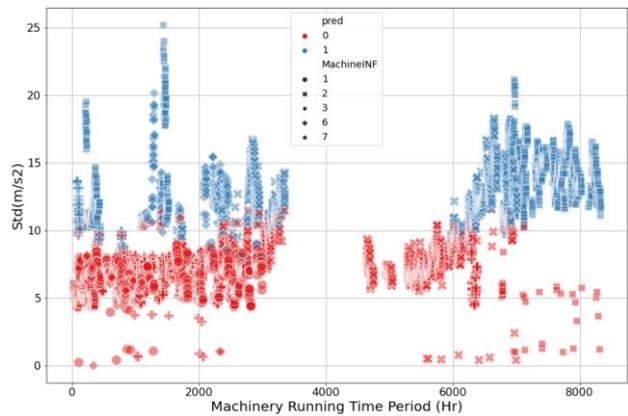


Fig. 7 Two levels clustering by k-means for CAE 10 features using 10000 data points, 60 Epoch. Scatter plot for Standard Deviation (Std) versus Rotation machinery running time period.

Table 3 Variation of NMI by Epoch and Number of measured data points. ‘-’ means not calculated yet.

Epoch	Number of measured data points			
	5000	10000	15000	20000
10	-	0.4620	0.5324	0.1592
20	-	0.4867	0.6461	0.2424
30	0.0245	0.5103	0.6135	0.1236
40	0.0219	0.6074	0.4913	0.2292
50	0.0086	0.6197	0.4779	0.1513
60	0.0069	0.7722	0.4913	0.0435
90	0.0105	0.4834	0.3986	0.0585
100	0.0078	0.0002	0.0002	0.0360
150	0.0161	0.0034	0.0002	0.0635
200	0.0146	0.0001	0.0002	-
300	-	0.0454	-	-
400	0.0106	-	-	-

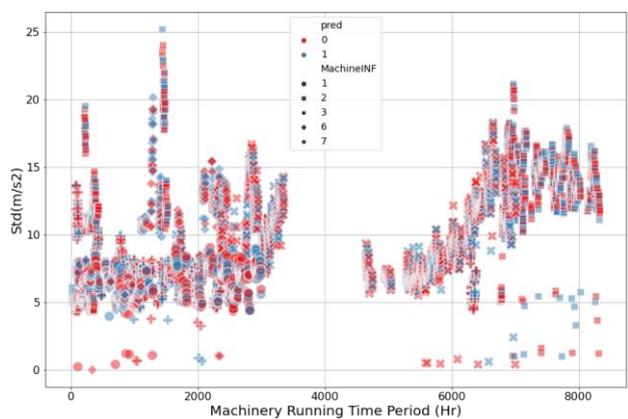


Fig. 8 Two levels clustering by k-means for CAE 10 features using 10000 data points, 300 Epoch. Scatter plot for Standard Deviation (Std) versus Rotation machinery running time period.

0.2 秒, 10000 点の測定データを切り出して計算した.

#### 5.4 NMI の探索

CAE のクラスタリング結果の妥当性を確認するため, NMI を最大化するポイントを検索する. NMI に影響するハイパーパラメータは, クラスター数, 測定データ点数, CAE の Epoch 数, ボトルネック次元数およびクラスタリング用の 2 次 CNN 次元数, カーネルの次元数およびサンプリング周波数などが考えられる. 今回は, 一般的に最も精度に影響すると思われる, 訓練データ点数と Epoch 数を変化させて NMI を計算し, その結果を Table 3 に示す.

異なった訓練データ点数の作成は, 同じ標本を利用し, 10000 点用のデータ開始時刻を基準にして, 切り出す点数を変化させて行っている. つまり, 5000 点のデータは 10000 点と同じ開始時刻で半分のデータ点数であるので, 10000 点の中に同じデータが全て含まれる. 同様に, 20000 点のデータは, やはり 10000 点と同じ開始時刻にして倍のデータ点数となる様に作成されている. Fig. 8 には, クラスタリングできなかつた場合の例として, 測定データ点数 10000 点で 300Epoch の特徴量を 2 クラスタリングした結果を示す.

#### 5.5 3 クラスタリングの評価

Fig. 7 の結果を 3 クラスタリングに変更した例を Fig. 9 に示す. 境界は入り組んでいるが, 概略として 1), 2), 3) の各層に分ける破線を直線で記載した. また, 整備記録と照合した結果を A), B), C) として枠で囲った. A) の時間帯に関する記録は無かつたが, 整備基準によれば, 6000 時間以降はベアリングの寿命に注意監視が必要な時間帯に属している. B) の部分については, ベアリングの摩耗であると推定されていたが, 基準寿命時間前であったので, 継続使用で様子が見られていた. 最終的に, ベアリングの交換が

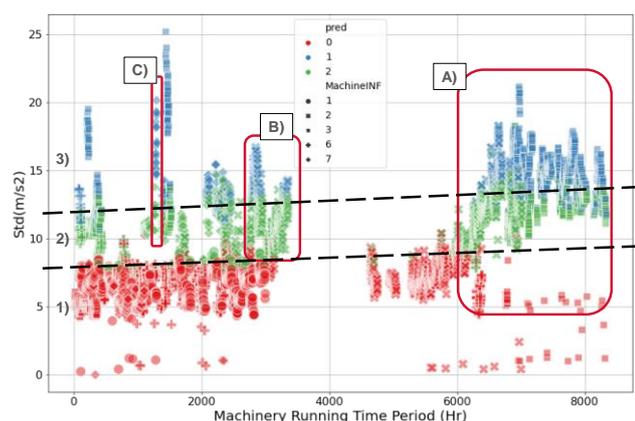


Fig. 9 Three levels clustering by k-means for CAE 10 features using 10000 data points, 60 Epoch. Scatter plot for Standard Deviation (Std) versus Rotation machinery running time period. Added 2 dashed lines to the boundary of 1)2)3), and added red frames A)B)C) to the time zone recorded in the maintenance logbook, by hand.

行われた. C)の部分については, 通常は発生しない保持機構部の部品の破損が見つかり, 交換が行われた. ほか, 2500 時間以下で, 正常部分から窓を開けて急激に増加している部分の整備記録は無かつた.

## 6. 考察

CAE のボトルネック特徴量を CNN で次元削減した特徴量の k-means によるクラスタリング結果は, ドメイン特徴量 Std をクラスタリングした結果と, NMI で 0.77 と高い類似性があつた. CAE によるクラスタリング境界は, Std より入り組んでいるが, どちらも 10 m/s<sup>2</sup> 付近を境界にして, Std の大小によって 2 つのクラスに区分されており, 類似の閾値となつた. さらに 3 クラスタリングした結果も, Std 軸方向に層状に構成されたことから, 提案する手法は, 加速度信号を Std に比例してクラスタリング可能な特徴量に次元削減する特性があると考えられる.

クラスタリングで得られた閾値を絶対的な判断基準とはできないが, ドメイン知識による管理基準として設備固有の Std の閾値を指定している場合, 本手法によって加速度信号から直接に正常異常の判断が可能になる. 今回の場合, 2 層における評価の結果では, 双方の境界がほぼ同等であることから, 10m/s<sup>2</sup> を評価指標として使用可能と考えられる. さらに, クラスタリング数を上げて, 正常, 軽度の異常, 重度の異常など, 多水準の閾値を異常度合いとして設定する監視にも利用できると考える.

Table 3 によれば, NMI は極大値を持つことから, NMI の最大化を利用して, ドメイン特徴量と類似したクラスタリングになるように, ハイパーパラメータを探索することが可能である. ただし, 単純に CAE の復元誤差を最小化する方向が, NMI の最大化とは一致していないため, 期待していた, ボトルネック特徴量とドメイン特徴量が類似の潜在変数空間を持つ方向に次元削減される, ことは実現していないと思われる. 測定データ点数が 10000 点の時に, 60Epoch で Encode した場合が最大であり, 60Epoch を超えると極端に低下している. 測定データ点数が 15000 点に増えた場合は, NMI の最大値が 0.64 と低くなる一方で, 20Epoch と Epoch 数が少ない方向に移動している. また, 測定データ点数が 20000 点の場合は有効なクラスタリングができていない. 2 次 CNN は誤差関数を持たないため, CAE のボトルネック特徴量で k-means が可能な程度の復元誤差, つまり分布を残しておくことが必要に思えるが, 復元誤差が大きい 5000 点ではクラスタリングができていない理由が不明である. 提案する手法の特徴量の構造を明らかにするため, さらに調査する必要がある.

Fig. 9 において, 設備的異常の Std 軸上における発現の仕方は, 大きく分けて, A), B) のように, 初期段階でなだらかに上昇した後で高止まりする現象と, C) の様に正常な位置から窓を開けて短期に急激に発生する 2 種類に分かれて

いた。A), B)は転がり軸受を持つベアリングの摩耗による劣化の振動の特徴に、C)は突発的な部品の破損の特徴として捉えることが可能である。この様に、クラスタリングをドメイン指標で評価した場合、異常の種類を特定する特徴量の抽出を行える可能性があるため、網羅的なデータの収集にも一定の効果があると考えられる。

今回の実験では、使用時間が短い場合でも Std としては大きな変動があった。2000 時間以下で、特定されていない急激な変動は、日常点検で見逃されたか、プロセス変動に起因した一過性の変動の可能性はあるが、生産としては正常に行われており、通常は異常と認識されない可能性が高い。正常値からの逸脱を検知しようとする機械学習応用システムを構築する場合、深層学習では、正常状態の学習に用いる訓練データから抽出される特徴量の構造を予め特定できないため、これらの不明な変動が、特徴量の生成に影響を与えていないか、判定の基準も必要と思われる。

## 7. おわりと今後の展望

本報告では、機械学習応用システムにおける、量と質の問題を解決する状態検知手法として、CAE による次元削減を用いたクラスタリングのワークフローを提案した。CAE によってアノテーションが不要になり、説明性のある構造を併せ持つことでクラスタリング結果に対する評価が可能になるように設計した。プロトタイプを実際の工程に適用した結果、Std 軸上に 2 層または 3 層に層別された状態を表現することが可能であり、ドメイン基準相当の評価指標として使用可能と考える。

一方で、最適化と CAE 特徴量の説明の課題が残った。Epoch 数と測定データ点数を調整することによって NMI を最大化し、ドメイン特徴量のクラスタリングに類似させることが可能であったが、他の変数までは調べ切れていない。また、双方の特徴量の潜在変数空間における構造も不明であり、なぜ類似した結果となったかは説明できない。今回作成したネットワークは、画像用としては基本的なものであり、層数、Epoch 数ともに少ない領域である程度結果がでてくる。仮に、加速度の異常の種類に合わせて、ImageNet の様なデータベース化が可能であるとすれば、特徴量の抽出と分類は、画像ほど複雑でない可能性がある。今後、ボトルネック特徴量の分布を仮定できる変分オートエンコーダのような手法を用いるなど、ネットワークを最適化しつつ潜在変数空間上の構造を明らかにして、同時に異常の種類についても特定可能かどうか検討を行いたい。

**謝辞** 本研究は、enPiT-Pro スマートエスイー：スマートシステム&サービス技術の産業連携イノベティブ人材育成（研究代表校：早稲田大学）の助成を受けて行われました。本報告をまとめるにあたり、適切な助言を賜りました。鷺崎先生、吉岡先生に感謝致します。

## 参考文献

- [1] 井出剛著,入門 機械学習による異常検知,2015
- [2] 梅田ほか: IoT 機器の時系列データ処理への取り組み,計測と制御,第 58 巻,第 9 号,2019 年 9 月
- [3] 太田聡: 時系列データに対する異常検知のための教師なし学習,MSS 技報・Vol31,2021.03.01
- [4] 真矢,植野: 深層学習を用いた時系列異常検知手法の提案,応用数理,VOL.30 NO.1 MAR. 2020
- [5] 小林,関根: 多様な動作パターンをもつ機器に適用可能な振動データを用いた故障予兆検知手法,OKI テクニカルレビュー,第 233 号 Vol.86 No.1, 2019
- [6] 長谷川ほか: 回転機器状態監視のための振動異常検知システムにおける特徴量表現学習,人工知能学会,2019
- [7] 丸山宏: 機械学習工学に向けて,日本ソフトウェア科学会第 34 回大会(2017 年度) 講演論文集
- [8] Scott M. Lundberg, et.al: Explainable AI for Trees: From Local Explanations to Global Understanding, arXiv:1905.04610
- [9] 石川,徳本: 機械学習応用システムのテストと検証,情報処理,Vol.60 No.1 Jan. 2019
- [10] CRDS 国立研究開発法人科学技術振興機構 研究開発戦略センター,CRDS-FY2020-FR-02, 研究開発の俯瞰報告書 システム・情報科学技術分野,2.1.4 AI ソフトウェア工学 (2021 年)
- [11] 鷺崎弘宜: 機械学習デザインパターンおよび機械学習システムの品質保証の取り組み,ソフトウェアエンジニアリングシンポジウム 2021
- [12] 栗原ほか: 機械学習によるセンサー異常値検出,FIT2015 (第 14 回情報科学技術フォーラム) ,2015
- [13] 坂本ほか: IoT による工場内設備の運転状態監視と異常発報システムの開発,長野県工技センター研報,No.15,p.E6-E9,2020
- [14] 広瀬ほか: 加速度信号を用いた溶接ロボットの異常検知モデルの開発,自動車技術会論文集,Vol52,No.3,May 2021
- [15] 朝日翔太ほか: 再帰型オートエンコーダを用いた振動データによる工場設備の故障予測手法の提案,日本機械学会論文集,Vol.86,No.891,2020
- [16] 郭家寧ほか: オートエンコーダを用いた地震計の時系列異常検知, The 34th Annual Conference of the Japanese Society for Artificial Intelligence, 2020
- [17] G.E.Hinton and R.R. Salakhutdinov: Reducing the Dimensionality of Data with Neural Networks, SCIENCE, 2006
- [18] 櫻田,矢入: オートエンコーダを用いた次元削減による宇宙機の異常検知, The 28th Annual Conference of the Japanese Society for Artificial Intelligence, 2014
- [19] M. Munir, S. A. Siddiqui, A. Dengel and S. Ahmed, "DeepAnT: A Deep Learning Approach for Unsupervised Anomaly Detection in Time Series," in IEEE Access, vol. 7, pp. 1991-2005, 2019, doi: 10.1109/ACCESS.2018.2886457.
- [20] Mathilde et, al: Deep Clustering for Unsupervised Learning of Visual Features, arXiv, 2019
- [21] Si Lu and Ruisi Li: DAC: Deep Autoencoder-based Clustering, a General Deep Learning Framework of Representation Learning, Intelligent Systems Conference (IntelliSys) 2021 (Accepted)
- [22] Scikit-learn: Machine Learning in Python, Pedregosa et al., JMLR 12, pp. 2825-2830, 2011.
- [23] 株式会社滑潤滑通信社,基礎から学ぶ大型回転機械の状態監視と診断,p16