

機械学習の活用による異常診断技術の応用

Development of Anomaly Diagnostic Technology using Machine Learning

長 島 瞳 高度情報マネジメント統括本部 IoT プロジェクト部
長谷川 雄 大 高度情報マネジメント統括本部 IoT プロジェクト部
茂 木 悠 佑 高度情報マネジメント統括本部 IoT プロジェクト部
河 野 幸 弘 高度情報マネジメント統括本部 IoT プロジェクト部 部長

株式会社 IHI は、機械学習手法の一つである MT 法を用いた設備の異常診断に取り組んできた。この方法は、設備が正常状態であるときの稼働データを学習させ、診断時のデータがそこから離れている場合に異常と判断する手法である。しかし、設備の動作モードや外気温などの設備の動作環境が変化すると、基準となる正常状態も変化してしまうため、誤検知・未検知が発生していた。この問題を解決するために、時々刻々と変化する運転状況に適した正常状態のデータを選ぶことによって高い精度で診断を行える方法を開発した。本稿では開発した手法の概要とその検証結果を紹介する。

IHI has been working on anomaly diagnosis for plant equipment using the MT method, which is a machine learning method. In this method, the operational data when the equipment is in a normal condition is learned in advance, and if the data at the time of diagnosis deviates from the reference value, it is diagnosed as being abnormal. However, if there is a change in the equipment operating environment, such as the equipment operating mode or the outside temperature, the reference value of the normal condition also changes, then, erroneous detection occurs. In order to solve this problem, we have developed a new method. The method makes the diagnosis highly accurate by selecting normal condition data which is suitable for the operating situation, which changes from moment to moment. This article outlines the developed method and give the results of its verification.

1. 緒 言

お客さまに納めた設備が予期せず故障してしまうと、生産活動や営業活動を停止させることになり、お客さまの大きな損失となってしまいます。したがって、設備の計画外停止をなくし、長期間安定して稼働させ続けて稼働率を高めることが、お客さまにとって高い価値につながる。これを実現するためには、故障が起る前の異常な状態を見つけて故障の予兆を捉え、事前にメンテナンスなどの対応を行うことが重要である。最近の IoT 技術の発展によって、設備に取り付けたセンサから設備の稼働データが容易に収集できるようになり、設備の稼働データを分析することで異常を検知する異常診断が従来にも増して活用され始めている。

異常診断によく用いられる一般的な方法としてリミットチェックがある。リミットチェックは、監視するすべてのセンサの値（以下、計測値）にあらかじめ正常範囲の上下限值（リミット値）を設定しておき、計測値の現在の値が上下限値を外れた場合に、異常の可能性があると診断するものである。しかし IHI グループの製品にはプラン

トなどのように、多くのセンサが取り付けられた複雑な設備もあり、上下限値の設定や異常を検知する計測値の数が膨大となり、監視が課題になっていた。

この問題の解決手法として 2 章に示す MT (Mahalanobis Taguchi) 法^{(1)~(3)}がある。しかし、設備の動作環境が変化する場合、MT 法による診断では、誤検知や未検知が発生する問題があった。

本稿では、まず、MT 法の概念とその問題点について簡単に触れ、次に問題を解決する提案手法を示す。

2. M T 法

2.1 MT 法とは

MT 法は、機械学習手法の一つであり、多くのセンサをもつ設備から得られる膨大な計測値に対する異常診断を、効果的に行える手法である。この手法では、単位空間と呼ばれる設備の正常状態時の稼働データ（以下、正常データ）を診断の基準とし、診断時の稼働データがその単位空間から離れている場合を異常と判断する。その離れ具合を、単位空間の分布を考慮して算出されるマハラノビス距離 (Mahalanobis Distance, 以下、MD 値) を使って

測る。MD 値が大きい場合は単位空間から遠い状態、すなわち正常状態から離れている状態を異常と判断する。第 1 図に MT 法による診断の概念図を示す。

MT 法による診断手法のメリットを以下に示す。

(1) 多くの計測値を一次元に集約

診断の対象とするすべての計測値を一つの指標 (MD 値) に集約するため、多くのセンサをもつ設備でも正常・異常の判断が容易である。

(2) 相関関係の崩れも検知可能

MD 値は、各計測値の大きさだけでなく、計測値間の相関関係も考慮して計算される。そのため、各計測値は正常範囲内だが、計測値間の相関関係が崩れているリミットチェックでは見逃される異常も検知可能である。

(3) 発生する頻度が低い異常も検知可能

MT 法は、正常状態のみを学習し、そこからの離れ具合で異常を検知する。そのため、過去に発生したことがない異常であっても、正常状態から離れていれば、異常として検知可能である。

2.2 MT 法の問題点

異常診断に適用する場合、単位空間は設備の正常データからなるが、設備の動作環境 (外部環境や運転条件など)

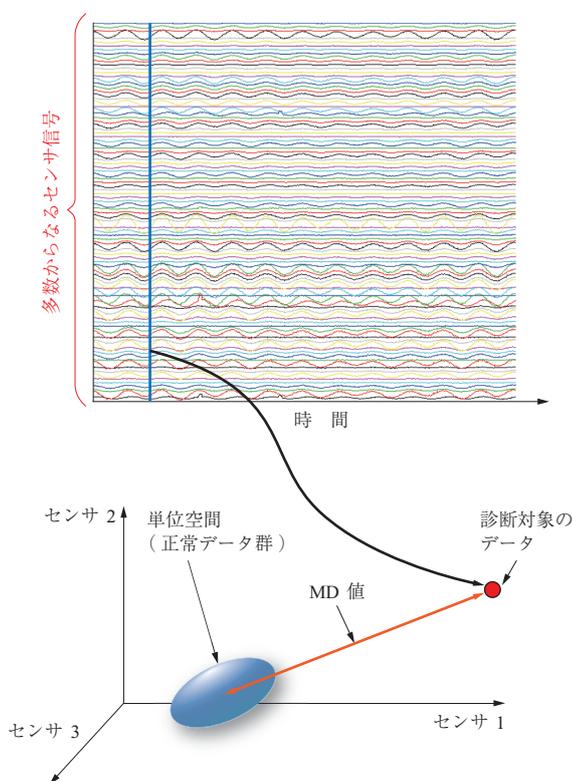
が変化すると、正常状態も変化する。外部環境の変化の例として、気温、気圧の変化による状態変化などがあり、運転条件の変化の例としては、設定回転数、設定温度など、オペレーションの変更による状態変化がある。

正常状態が絶えず変化するときに、あらかじめ定めた正常データのみを使って生成した固定の単位空間を用いて診断した場合の診断対象の計測値と正常範囲を第 2 図に示す。すると以下のような問題が生じる。

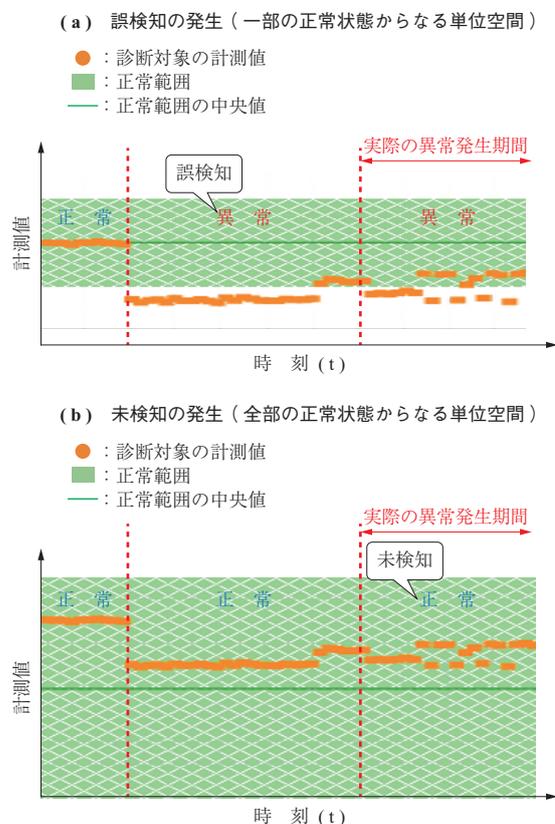
(1) ある一部の正常データのみを使って単位空間を生成した場合、別の正常状態のデータを異常と判断し、誤検知が発生する。

(2) すべての正常データを使って、単位空間を生成した場合、異常なデータを正常と判断し、未検知が発生する。

これらの問題に対処する方法の一つとして、あらかじめ異なる正常状態ごとに、別々の単位空間を事前に生成しておき、それらを状況に応じて使い分ける方法がある。しかし、設備の状態は一般的に有限の個数ではなく無数にあるため、正常状態も同様に無数に存在することになり、単位空間を個々に設定できない。したがって、あらかじめ生成した複数の単位空間を使い分ける方法は適用が難しい。



第 1 図 MT 法の診断概念図
Fig. 1 MT method concept



第 2 図 固定した単位空間による問題
Fig. 2 Problem using fixed unit space

そこで、設備の正常状態が無数に存在する場合にも誤検知や未検知の発生を極力抑え、精度よく診断できる手法を検討することで、3章に示す方法を開発した。

3. 提案手法

2章で述べた問題の解決手法⁽⁴⁾として、診断ごとにその設備の動作環境に応じた単位空間を生成する方法を考案した。診断ごとに単位空間を生成させるため、本稿では動的単位空間と呼ぶ。動的単位空間を用いると、事前に単位空間を切り分ける必要がない。

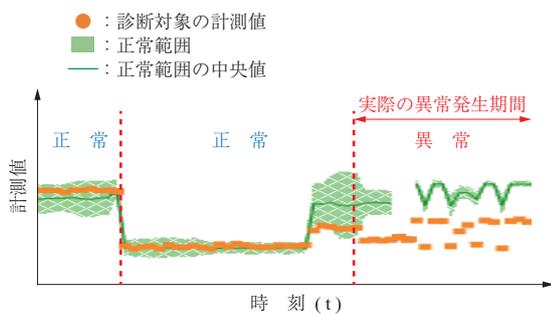
正常状態が絶えず変化するとき、動的単位空間を用いて診断した場合の診断対象の計測値と、正常範囲を第3図に示す。すると、第3図のとおり設備の動作環境に追従しながら診断するため、誤検知や未検知を減少させられる。

この動的単位空間の処理を、既存のMT法の処理に加えたものが本稿の提案手法である。第4図に、通常のMT法の診断フローと、動的単位空間の処理を組み込んだMT法の診断フローを示す。

動的単位空間の生成は、診断対象データである設備の稼働データを取得するたびに行う。

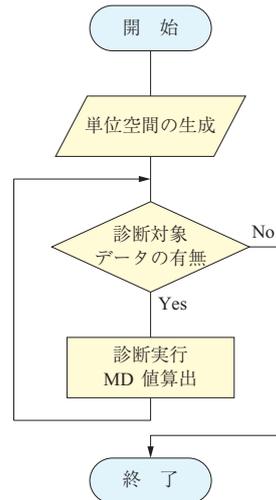
第4図のAで示された箇所では、診断対象の稼働データを基に設備の動作環境を推定し、過去の正常データの中から動作環境に近い稼働データのみを使った動的単位空間の生成処理が行われる。

診断ごとに単位空間を構成する正常データが異なるため、本稿では詳細を割愛するが、動的単位空間内のデータに基づいて、異常と判定するためのMD値のしきい値をあらかじめ学習させておき、診断ごとに最適な判定しきい値を推定している。以下、この判定しきい値を動的判定しきい値と呼ぶ。

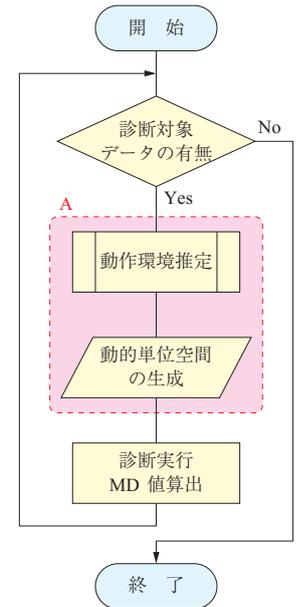


第3図 動的単位空間による診断
Fig. 3 Diagnoses using adaptive unit space

(a) 通常のMT法



(b) 動的単位空間処理を用いたMT法



第4図 診断フローの比較
Fig. 4 Comparison of both diagnostic flow charts

4. 検証

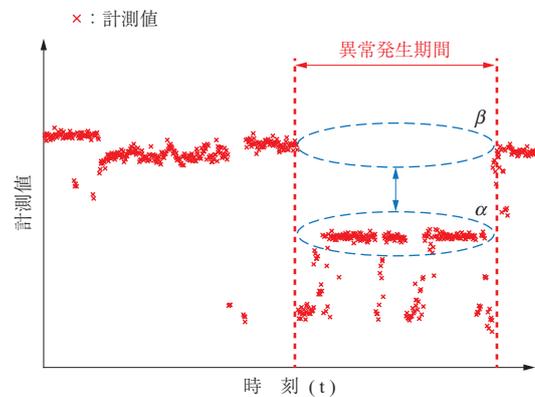
4.1 検証条件

提案手法の有効性を、実際に設備の動作環境が変化するなかで取得された稼働データを用いて検証した。検証に用いた設備のセンサ数は440である。

学習用データとして、動的単位空間を生成する基となる正常データを含むデータ群(A)、および検証用データとして正常状態時と異常状態時の稼働データを含むデータ群(B)を用いた。データ群(A)、データ群(B)のデータ点数は、それぞれ71180点、558点である。

データ群(B)に含まれる異常状態時の稼働データのトレンドグラフを第5図に示す。

第5図に示した期間のうち、点線で囲んだ箇所αは、



第5図 異常状態時のトレンドグラフ
Fig. 5 Trend graph during abnormal conditions

本来の出力から想定される計測値の範囲 β より低い水準にとどまっている。この期間が異常発生期間である。

データ群 (B) の各点において、正常と異常のラベル付けを行った。第 1 表に、データ群 (B) の各ラベルの点数の内訳を示す。

4.2 検証結果

第 6 図に、診断結果とトレンドを示す。

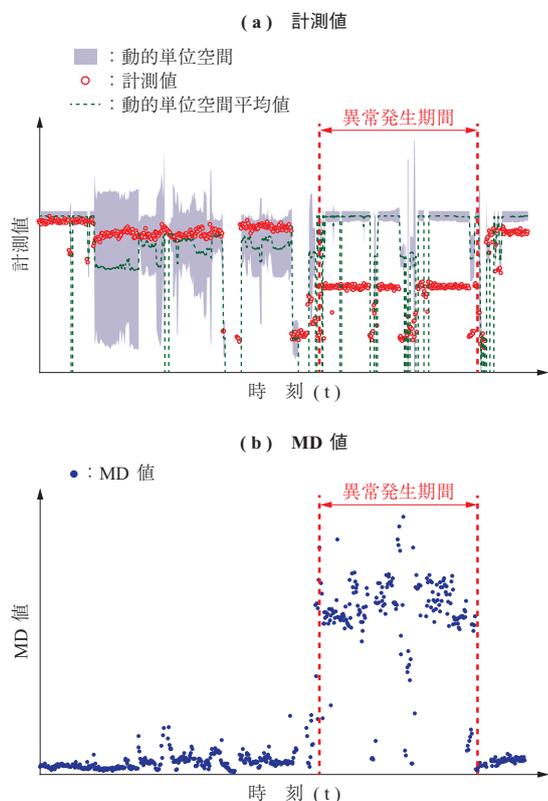
第 6 図 - (a) では、計測値と動的単位空間の範囲およびその平均値を示している。

第 6 図 - (b) では、計算された MD 値を示しており、異常発生期間において MD 値が増大し、異常を適切に検知できていることが分かる。

次に、従来の MT 法である固定の単位空間および固定の判定しきい値を用いた診断方法、および今回の提案手法である動的単位空間および動的判定しきい値を用いた診断方法のそれぞれの精度を比較検証した。第 2 表に混同行

第 1 表 データ群 (B) ラベル内訳
Table 1 Breakdown of label

ラベル	データ点数
異常	181
正常	377
合計	558



第 6 図 診断結果のトレンドグラフ
Fig. 6 Trend graph of diagnostic results

第 2 表 混同行列による検証結果
Table 2 Verification result by confusion matrix

		診断		検出率 (%)	
		異常	正常		
従来の MT 法	実際	異常	TP 96	FN 85	53 (再現率)
		正常	FP 0	TN 377	100
	精度 (%)	100	82	-	
提案手法	実際	異常	TP 167	FN 14	92 (再現率)
		正常	FP 0	TN 377	100
	精度 (%)	100	96	-	

(注) TP : True Positive
FN : False Negative
FP : False Positive
TN : True Negative

列による検証結果を示す。従来の MT 法を用いた診断方法の再現率 (実際に異常だったデータを異常と診断した率) が 53% であるのに対し、提案手法の再現率は 92% と大きく向上し、高い診断精度を達成した。

4.3 考察

設備の動作環境の変化により正常状態が無数に存在する場合でも、動的単位空間を導入することによって、精度の高い異常診断が可能になることが分かった。この提案手法によって、従来の MT 法で診断が難しかった性質の設備にも対応可能となり、診断できる設備の範囲が大きく広がるものと期待される。

5. 結 言

動的単位空間の概念は、動作環境が変化する設備などに対して、誤検知や未検知の少ない診断を可能とする。また、単位空間を適切に生成することによって診断精度が向上し、故障の予兆につながるような異常の微小な変化を捉えることが可能となり、お客さまの設備の計画外停止を低減する効果が期待できる。

クラウド上で集まったデータを、本稿の提案手法を用いて診断する異常診断ツール I-ASTA® (IHI Adaptive Statistical Analyzer) は、多くのセンサをもつプラントに対して、幾つかの故障の予兆を実際に検知することに成功している。

さらに、提案手法の診断処理を高速化して異常診断を設備側 (エッジ側) で行う I-ASTA Edge では、診断対象のセンサ数にも依存するが、10 ms 程度の周期で診断可能である。これによって、回転機など動作の速い設備にも診断対象を拡大できるため、より広範囲の設備に提案手法の適用が可能となった。

今後も、さまざまな設備の計画外停止の防止によって稼働率を向上させることでお客様の価値向上に貢献していく。

参 考 文 献

- (1) 田口玄一著, 矢野 宏編: 田口玄一論説集第 4 卷, 一般財団法人日本規格協会, 2012 年 2 月
- (2) 田村希志臣: よくわかる MT システム 品質工学によるパターン認識の新技术, 一般財団法人日本規格協会, 2009 年 8 月
- (3) 袖子田志保, 木村麻衣, 鈴木由宇, 近藤智佳子: データ解析による予防保全技術の開発, IHI 技報, Vol. 54, No. 2, 2014 年 6 月, pp. 26 - 31
- (4) 茂木悠佑: 単位空間を動的に生成することによる, 機械設備・プラント異常診断の精度向上, 品質工学会第 27 回品質工学研究発表大会, 2019 年 6 月