

障害診断のための異常パターンマイニング

藤巻遼平¹中田貴之¹塚原英徳²佐藤彰典²山西健司¹¹NEC 共通基盤ソフトウェア研究所†²NEC ITS 事業推進センター‡

Abstract: 本稿は故障事象の検出問題に関し、A) 各属性 (時系列データ) の性質が異種多様、B) 故障事象の学習事例が少数、C) 故障事象とは無関係な属性が多く含まれる、という実用でしばしば直面する状況で、高精度な診断を可能とするアルゴリズムを提案する。提案アルゴリズムの特徴は、1) 各属性の時系列を異常スコアの列へ変換し各属性の異常スコアベクトルによって各故障を特徴付ける、2) 故障時および正常時の異常スコアベクトルを利用して適切な属性を選択する、という 2 点からなる。実験では自動車の実データに対して提案アルゴリズムを適用し、その有効性を確認した。

1 はじめに

近年、機械システムに設置されたセンサ等から取得される時系列データをリアルタイムで解析し、故障を検出する試みが注目を集めている [3, 6, 7]. これは、自動車、列車、通信衛星などの故障を早期に検出する事によって、重大な事故や障害を回避するための有効な手段である。この際、複雑な機械システムの動作モデルや故障検出ルールを専門家が網羅的に作成する事は難しく、データから故障検出モデルを獲得する事が重要となる。

過去に発生した故障をデータマイニングや機械学習技術を利用して検出する場合には、時系列的に得られるデータを高速に処理すると共に、A) 各属性 (各時系列) の性質が実数値やシンボル値であったり、スケール、物理的性質が異なるなど異種多様、B) 故障事象の学習事例が少数のため通常の教師付学習 [1, 2, 4] は過学習となりやすい、C) 故障事象とは無関係な属性が多く含まれ誤警報が増加する、という難題を同時に解決する必要がある。これは、実用上必須の要求項目であると共に、技術的観点からも非常にチャレンジングな課題と言える。

本稿では、この問題に対して異常パターンマイニングを提案する。上記 A) から C) の課題を解決するための技術的ポイントは、1) 異常スコア表現 (Anomaly Score based Representation; ASR), 2) 異常パターンに基づく属性選択 (Abnormal Pattern based Feature Selection; APFS), の 2 点である。

2 異常パターンマイニング

図 1 に異常パターンマイニングの概要を示す。学習では ASR および APFS によって異常パターンを生成する。診断では異常パターンと診断データの異常スコアベクトルを比較して故障の検出を行なう。ASR はスコアリングおよび異常スコアベクトル化の 2 つの処理から成る。

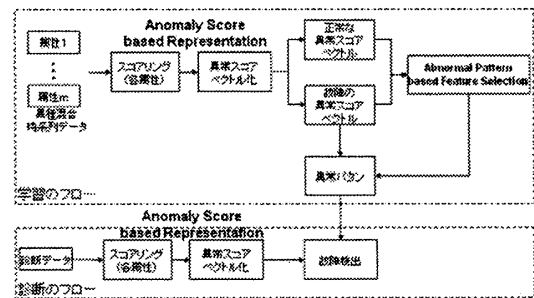


図 1: 異常パターンマイニングの概要

2.1 ASR

スコアリング: 入力された各時系列データをそれぞれ異常スコアの列へ変換する。時系列に対する異常スコアとしては、外れ値スコアと変化点スコアの 2 種類が考えられるが、本稿では変化点スコアを利用する。これは、故障が発生した場合にはシステムの挙動に本質的な変化が発生し、それがデータに現れると考えられるためである。変化点スコアの計算方法は任意であるが、本稿では Takeuchi [5] らの提案する変化点検出アルゴリズムを利用した。以下、 x_t^i を学習データの時刻 t における属性 i の異常スコアの値とする。

異常スコアベクトル化: 各属性の異常スコアを並べたベクトル $x_t = (x_t^1, \dots, x_t^d)$ を生成する。 d は属性の数。異常スコアベクトルは、各属性の異常な挙動の共起を表現し、特に変化点スコアを利用している場合には以下、 z_t および y_t は正常および故障の異常スコアベクトルとする。

ASR の利点: ASR には大きく 2 つの利点がある。1 点目は、各属性をスコア空間に写像する事で元空間の性質の違いを意識する必要がなくなり、様々なベクトルに対する最適化を行なえる点。2 点目は、各属性の異常や変化だけに着目する事で、学習と診断データの性質の違いを吸収できる点¹。この二つの利点によって、第 1 章

Title: Mining Abnormal Patterns for Fault Event Detection
Author: Ryohei Fujimaki, Takayuki Nakata, Hidenori Tsukahara, Akinori Sato, Kenji Yamanishi

†NEC Common Platform Software Research Labs.

‡NEC ITS Business Development Center

¹自動車を例にすると、時速 30km、外気温 25 度、エンジン回転数 1500rpm である故障が起こった場合と時速 200km、外気温 5 度、エンジン回転数 4000rpm で同一の故障が起こった場合では、元空間における性質はまったく異なるが、故障発生時に影響を受ける属性は類似していると考えられる。

で述べた課題 A) および B) を解決する事が可能である。

2.2 異常パタンの生成

異常パターンは、故障時の異常スコアベクトルの平均、 $\bar{y} = \frac{1}{M} \sum_{\tau=1}^M y_{\tau}$ として表現される。故障検出は、異常パターンを参照パターンとして、入力データの異常スコアベクトルを診断する。この時、両者間の距離を、重み付ユークリッド距離、 $d(x, \bar{y}) = \sum_{i=1}^m w_i (x^i - (\bar{y})^i)^2$ として定義する。

各属性の寄与 w_i は、 $w_i = 0$ の場合、故障とその属性が無関係となるため、 w_i の計算は属性選択問題と捉える事が可能である。次節で、2点目のポイントである APFS に関して説明をする。

2.3 APFS

APFS は、1) 故障と正常の異常スコアベクトル間の距離の最大化、2) 故障時の異常スコアベクトル間の距離の最小化、3) 故障と類似したデータと故障データ間の距離の最大化、という3つの基準を同時に最適化することで w_i を計算する。

第1および第2の基準は、Fisher の判別分析 [2] などと類似の考え方に基づく基準である。第3の基準は、故障と物理的に類似した事象が正常時に発生する可能性があるという、故障診断特有の問題に起因する基準である²。この最も単純な例としては、自動車におけるエンスト故障と運転者による手動のエンジンの ON/OFF などが挙げられる。ただし、どのデータが故障と類似しているかは事前にはわからないため、属性の重要度 w_i と同時に、正常データの故障データに対する類似度 α も同時に推定する必要がある。

(1) に、APFS の最適化問題をまとめる。

$$w^*, \alpha^* = \arg \max_{w, \alpha} \{ J_1(w) + J_2(w, \alpha) + J_3(w) + J_4(w, \alpha) \},$$

$$\text{subject to } w'w = 1, w_i \geq 0, \alpha' \alpha = 1, \alpha_t \geq 0. \quad (1)$$

$$J_1(w) = \sum_{i=1}^m w_i (\bar{y}^i - E[x_t^i])^2,$$

$$J_2(w) = - \sum_{i=1}^m w_i \sum_{j,k} \frac{1}{M^2} (y_j^i - y_k^i)^2,$$

$$J_3(w, \alpha) = \sum_{i=1}^m w_i \sum_{t=1}^N \alpha_t (|x_t^i - \bar{y}^i| - E[|x_t^i - \bar{y}^i|])^2,$$

$$J_4(w, \alpha) = -\gamma \sum_{i=1}^m |w_i| - \eta \sum_{t=1}^N |\alpha_t| \quad (\gamma \geq 0, \eta \geq 0).$$

紙面の都合により詳細な説明は割愛するが、 J_1 から J_3 によって第1から第3の評価基準を表現し、 J_4 は正則化の条件を表す。 w および α の最適化は同時には難し

²一般に、正常データ中の故障と類似したデータの比率は小さいため、第1の基準だけでは類似データが誤警報となりやすい。

表 1: 誤警報率の比較 (正答率 100%時)

	エンスト	アイドル不安定
KNN-LDA	16.6%	11.6%
KNN-LDA-ASS	12.3%	3.5%
APM	0.02%	0.07%

いため、各変数に対する最適化を繰り返し解く事によって最適解 w^* および α^* を計算する。各変数に対する最適化は解析解が求まるため、学習は効率的に行なう事が可能である。

3 実験と考察

実験は、強制的に故障を発生可能な評価用自動車の実走行データに対して提案手法を適用し、検出性能を評価した。学習データは 4053 点で、正常データ 4045 点、エンスト故障 6 点、アイドル不安定故障 2 点からなる。評価データは、7062 点で、正常データ 7048 点、エンスト故障 12 点、アイドル不安定故障 2 点からなる。

異常パターンマイニング (APM) および異常スコア空間における K 近傍識別器+判別分析 (KNN-LDA-ASS)、元空間における K 近傍識別器+判別分析 (KNN-LDA) を上記データに適用した時の誤警報率を表 1 に示す。APM では劇的に誤警報率が削減され、性能が向上している事が確認できる。

4 まとめ

本稿では、故障検出のための異常パターンマイニングを提案し、その有効性を確認した。今後、提案手法を故障位置や原因の特定へ拡張予定である。

参考文献

- [1] M. Chen, A. X. Zheng, J. Lloyd, M. I. Jordan, and E. A. Brewer. Failure diagnosis using decision trees. In *Proceedings of the 1st ICAC*, pages 36–43, 2004.
- [2] R. A. Fisher. The use of multiple measurements in taxonomic problems. *Annals of Eugenics*, 7:179–188, 1936.
- [3] R. Fujimaki, T. Yairi, and K. Machida. An approach to spacecraft anomaly detection problem using kernel feature space. In *Proceeding of the 11th KDD*, pages 401–410, 2005.
- [4] Y. Li, Y.-Z. Cal, R.-P. Yin, and X.-M. Xu. Fault diagnosis based on support vector machine ensemble. In *Proceedings of 2005 International Conference on Machine Learning and Cybernetics*, pages 3309–3314, 2005.
- [5] J. Takeuchi and K. Yamanishi. A unifying framework for detecting outliers and change points from time series. *IEEE Transactions on Knowledge and Data Engineering*, 18(4):482–492, 2006.
- [6] V. Verma, G. Gordon, R. Simmons, and S. Thrun. Particle filters for rover fault diagnosis. In *IEEE Robotics and Automation*, 2004.
- [7] C. Yang and S. Letourneau. Learning to predict train wheel failures. In *Proceeding of the 11th KDD*, pages 516–525, 2005.