

変化点関連度を利用した動的システムの障害解析

井上 恵介[†] 井手 剛[†]

本手法は、機械システムに埋め込まれた多数のセンサから得られるような異種混合的な時系列データ群に対して、システム自体のモデルを作ることなく、変数の関係のみに着目して、背後にあるメカニズムを評価する。まず文献 1) で提案したように元のデータを変化度の時系列に変換し、特徴的な変化を顕在化する。そして、変数のペアがどの程度同期して変化したかを、変化度の時系列をもとに変化点関連度として定義する。すべての変数のペアに対して変化点関連度を計算して作った行列は、システムの操作履歴などによらず、メカニズム（因果関係）自体を反映するので、これにもとづき異なる状態（正常と異常）の比較や問題箇所の特定、過去の類似障害の検索などが可能になる。

Failure Analysis of Dynamic Systems based on Change-Point Correlation

KEISUKE INOUE[†] and TSUYOSHI IDÉ[†]

This paper proposes an approach for evaluating a dynamic system based on a set of time series obtained through embedded sensors. Those time series are heterogeneous and include irregular changes. The approach does not use any specific model, but correlates a pair of time series based on synchronicity of change points as we proposed in 1). Using dependency matrix consisting of change-point correlation for every pair of variables, the state of a dynamic system can be evaluated independently from the order of human operations etc. This can be used for failure analysis, root cause analysis, and trouble case search.

1. はじめに

近年、自動車や生産設備を始めとする機械システムは電子化の一途をたどり、埋め込まれたセンサーからの信号にもとづき、内蔵された IC チップを使って制御されるようになった。機械といえどもかつてのようにリンク機構などによって操作が伝達されるのではなく、操作やシステムの内部状態が電気信号に一旦変換され、アルゴリズムが適切な動作を決定した後で、それが電氣的にアクチュエータに伝達される。その一例が自動車のパワーステアリングである。

電子制御化の進展は、制御ロジックを複雑化させ製品の高機能化を実現した。しかし同時に、機械システムの故障や不具合も複雑化し、障害の原因を追究する手間とコストが著しく増大した。もちろん、短期間に次々と新製品が設計・生産され障害の種類自体が増えていくことも、問題を難しくする要因である。こうした状況の中で、我々は、システムに埋め込まれた多数のセンサーからの情報を、制御だけでなく障害の診断や根本原因の特定に活用することを考えている。

自動車を例にとると、1 台あたり数十から数百もの多種多様なセンサーが埋め込まれており、それらからの信号はいくつかの ECU (Electric Control Unit) を通じて時々刻々集められている。例えば、エンジン回転数、ギ

ア位置、燃料流量、スロットル位置、吸気酸素濃度などである。これらの変数を時系列として仔細に観察すれば、システムの入出力や内部状態をほぼ完全に把握することができ、障害（不具合）の有無や発生箇所、原因の特定、ひいてはある程度の障害予測まで可能になるだろう。

こうした動的システムの障害解析の問題には、以下のような特徴がある。

- 変数の数が多く（数十から数百）、しかも異種混合的である。例えば温度、速度、圧力、濃度のように物理量としての次元もいろいろで、かつギア位置やスイッチのような離散値の変数もある。
- データが大量であり、人手のみに頼る解析は難しい。
- 人間の操作などの外的要因により、システムは定常状態ではなく、変数は不規則な激しい変化を含む。
- 変数どうしの間に強い拘束（依存）関係がある。

我々のアプローチは、システム全体を一種のブラックボックスと考え、すなわち特別なモデルを構築せずに変数相互の関係を調べることで、背後にあるメカニズムを評価しようというものである。言い換えれば、各変数の挙動は定常でなくても、それを支配する機構（メカニズム）自体は不変であるはずという前提である。

不規則な変動を含む時系列データについては、これまで多くの研究が行なわれており、フーリエ解析やウェーブレット解析、自己回帰モデルなどがよく知られている²⁾。また最近では、多数のアイテム間の相関規則を見出すことを目的とするデータマイニング³⁾の文脈から、時系列デー

[†] 日本アイ・ピー・エム（株）東京基礎研究所
Tokyo Research Laboratory, IBM Japan, Ltd.

タを扱おうという試みが盛んで、複数の時系列の相互関係の記述やそこから知識発見についての研究されている。しかし、異種多変量に対するモデルによらない手法の研究はまだ発展の途上にある。

以下第2章では、異種混合的な時系列に非線形変換をかけてから比較する方法を紹介し、第3章では、変数の因果関係に関する指標を使って変数セットを分析する手法を論ずる。続く第4章で時系列データを使った実験結果を示して考察し、最後に本報告をまとめる。

2. 特異スペクトル変換

2.1 変化点検出問題

変化点検出問題とは、そもそも何らかの変動やノイズを含んでいるような時系列データを観察し、そこに顕著な状況の変化があらわれたかを検知する問題である。どのような変化を顕著とみなすか(つまり検出するか)は、目的と手法によってさまざまである。例えば、入力が一値の周りに分布するような場合については、CUSUMと呼ばれる手法⁴⁾が使われる。他には、忘却係数を考慮して自己帰帰モデルを使う手法⁵⁾や、核関数法とヒューリスティックな尺度を応用して時系列を部分的に比較・分類する方法⁶⁾などが提案されている。しかしどれも、不規則かつ激しい変化を含むような異種多変量データへの適用が本来の目的ではない。

2.2 特異スペクトル解析法

最近、特異スペクトル解析法(singular spectrum analysis)⁷⁾という手法が知られるようになり、その変化点検出への応用をMoskvina-Zhigljavsky⁸⁾が提案している。この手法は、ふるまいの異なる変数に対しても有効かつ安定で、我々の用途に合うので、以下で概略を説明する。詳細は上記論文および文献1)を参照されたい。

時系列 $\mathcal{T} = \{x(1), x(2), \dots, x(t), \dots\}$ を考える。 t は時刻である。 \mathcal{T} の部分列として、長さ w の $\{x(t-w), \dots, x(t-2), x(t-1)\}$ を考え、対応する列ベクトルを

$$s(t-1) = (x(t-w), \dots, x(t-1))^T$$

と書く。上付きの T は転置を表す。この列ベクトルを並べて以下の行列を構成する(図1)。

$$H(t) = [s(t-k), \dots, s(t-2), s(t-1)].$$

この $w \times k$ 行列を、時刻 $t-1$ における履歴行列(trajjectory matrix)と呼び、参照する区間を示す。

履歴行列は、 $W = w + k - 1$ とおくと、時刻 $t-1$ から $t-W$ の計 W 個の要素からできており、これを以下のように特異値分解する。

$$H(t) = UD_\lambda V^T$$

ここで、 U, V は正規直交ベクトルを列ベクトルに持つ行列 ($U^T U = V^T V = I$)、 D_λ は $\lambda_1, \lambda_2, \dots, \lambda_r$ ($\lambda_1 \geq \lambda_2 \geq \dots \geq \lambda_r$) を対角要素とする対角行列である (r は $H(t)$ の階数)。このとき $w \times r$ 行列 U を構成する左特異ベクトル(長さは w)を左から順に u_1, u_2, \dots, u_r とすれば、参照区間(長さ W)における変化パターン(長さ




図1 特異スペクトル解析(左が履歴行列, 右がテストベクトル)




図2 超平面からの垂離による変化度 $z(t)$ ($l=2$ のとき)




図3 生データ(上段)と変化度時系列(下段)

w)の代表的なものを順に表している。

後ろにあるテストベクトルの特異性を評価するには、これら代表的パターンを示すベクトルのいくつか u_1, \dots, u_l で張られる超平面と、テストベクトル $s(t+w-1)$ との距離 $\|s(t+w-1) - \sum_{i=1}^l u_i^T s(t+w-1) u_i\|$ により、変化度 $z(t)$ を定義する(図2)。

2.3 特異スペクトル変換

上記のように、幅 W の参照区間をずらしながら代表パターンを逐次計算していくことで、各時刻 t において変化度を計算することができる。ここで、ある時系列 \mathcal{T} から、変化度 $z(t)$ の時系列 \mathcal{T}_c への変換

$$\mathcal{T} \rightarrow \mathcal{T}_c(W, w, l)$$

を特異スペクトル変換と定義する。カッコ内はこの変換で用いるパラメータである。この変換は、重ね合わせの原理を満たさない等の意味において、時系列 $x(t)$ の非線形変換といえる。

新しい時系列 $\mathcal{T}_c(W, w, l)$ は、元の時系列の表面的な挙動の陰に隠れた因果律の痕跡を、変化度という形で表している。したがって、変数の種類や性質によらず、変数どうしの関連を議論する土台となる。例えば、図3にかなり挙動の異なる2つのデータと、それに特異スペクトル変換を施した結果を示す。左では変曲点のような箇所、右では周波数が変わる点を変化として拾い上げており、両者の変化を同じ土俵で比較できることがわかる。

3. 変化点関連度による解析

3.1 関連度の定義

前節で導入した特異スペクトル変換¹⁾によって、時系

列データの物理次元、性質（連続／離散）や変化の激しさを問わずに、変化を数値化する方法が示された。この変化度を利用して、異種の時系列変数どうしの関係を、変化点関連度（change-point correlation）として数値化し、応用することを提案する。

変化点関連度は、2つの変数において顕著な変化がどれくらい同期して起きているか、ひいてはそれらの変数間に因果関係がどの程度ありそうか、という量である。趣旨としては相関（correlation）と似ているが、以下の点で相違がある。

- 変化度に一旦変換しているため、ふるまいや性質の異なった変数どうしの関連づけが可能である。
- 相関においては、データを2次元の点 $(x(t_i), y(t_i))$ の集合として評価するので時間軸は無視されるが、変化点関連度では考慮される。

変化点関連度は、2つの変数の変化度 $z(t), v(t)$ を比べ、どれくらい近いかを示す。定義は、決められた区間（全体でも可）で単位面積を囲むように変化度を正規化して $\tilde{z}(t), \tilde{v}(t)$ とし、それらの重なり面積 $R(z, v)$ とする。値は0以上1以下となる。

$$R(z, v) = \int \min(\tilde{z}(t), \tilde{v}(t)) dt$$

これを使って、変数どうしの距離を $d(z, v) = 1 - R(z, v)$ と定義することができる。

距離を定義する別法として、正規化された変化度が確率密度関数とみなせることから、確率密度関数に対してよく使われる Hellinger 距離などを使ってもよい。

3.2 関連度行列と視覚化

ある動的システムが異種多変量の時系列によって表されているとき、そこに含まれるあらゆる変数のペアに対して変化点関連度を計算し、それを並べたものを関連度行列（dependency matrix）と呼ぶ。関連度行列は変数の数の次元の対称行列であり、対角要素は1である。この行列は変数の因果関係のバランスを示したものであり、一つの動的システムの（継続的区間の）はたらきを代表する特徴量である。

関連度行列を、人間が理解しやすい形で視覚化する方法はいくつかある。関連度グラフ（図4）は、関連度行列をグラフの隣接行列と見て、閾値以上の関連度を持つ変数のペアを辺で結んだ重みつきグラフである。また、関連度行列は各変数間の距離を決定しているので、そこから変数のクラスタリングをすることで、システムの大まかな構造を見せることもできる。表示を自動的に行なうにはデンドログラムが適当である。

3.3 関連度によるデータセットの比較

関連度行列やその特徴量が動的システムのはたらき（状態）を表すとすれば、複数の動的システムの状態どうしを比較するのに利用できる。特に重要なのは、関連度になった時点で、時間軸方向の変化そのものは捨象されているため、一見して異なる挙動を示すシステムどうしを比較することができるということである。つまり、関連




図4 関連度グラフの比較による問題箇所（変数）の発見

度行列自体に類似性があれば、各変数の表面上のふるまいはともかく、それらを関連づけているメカニズム自体に共通性があることになる。

比較の方法には、関連度行列どうしの距離や、関連度グラフの差分（図4）、行列の特徴量（固有ベクトル）などが考えられる。そして、変数どうしの距離ではなく、今度は変数のセット（システム）どうしの距離によるクラスタリングができる。同じ変数セットを持つ動的システムの状態が分類できるので、例えば大量の障害事例の時系列データセットを予め分類しておき、新たな障害が発生したときに、類似事例を検索するのにも使える。

4. 実験

4.1 実験結果と考察

実験データとして、自動車に埋め込んだセンサーからの時系列データのセットを使用した。取得変数は40個、サンプル間隔は1秒、時間は約15分間である。取得区間の中で何らかの変化があった変数は12個あり、そのうちの6変数（アクセル位置、エンジン回転数、燃料噴射量、クラッチ、車速、冷却液温度）についての生データと変化度を図5に示した。変化度を計算する際の参照区間の幅は20秒程度、代表パターンの長さは10秒とした。信号の種類は離散値をとるものもあって多様だが、それぞれの特徴をとらえた変化度が計算できている。この例について、12個の変数を距離にもとづきクラスタリングした結果が、図6のデンドログラムである。このような視覚化は、関連度行列以上の情報を本質的に含むものではないが、人間に大まかな理解を与えるのに役に立つ。

次に、上記とは別のデータセット A-F に対し、それぞれの関連度行列を計算した。各データセットの特徴ベクトルとしてそれぞれの最大固有値に対応する固有ベクトルを用い、6つの特徴ベクトルに対して主成分分析を行なって、第一主成分と第二主成分の方向成分を2次元座標空間上にプロットしたのが図7である。同様に特徴ベクトル自身を、相関による距離にもとづきクラスタリングした結果のデンドログラムを図8に示す。両方のやり方で、同様のクラスタができていことがわかる。この3つのクラスタは、それぞれ異なる運転状態（A: アイドリング, B, C: 市街地走行, D-F: 高速走行）に対応していたので、予備知識なしで分類できたことになる。

4.2 今後の課題

実データによる実験を通じ、関連度解析を障害解析に応用する際の有効性が見えてきたが、同時に限界も明らかになってきた。当然のことだが、関連度解析はデータ

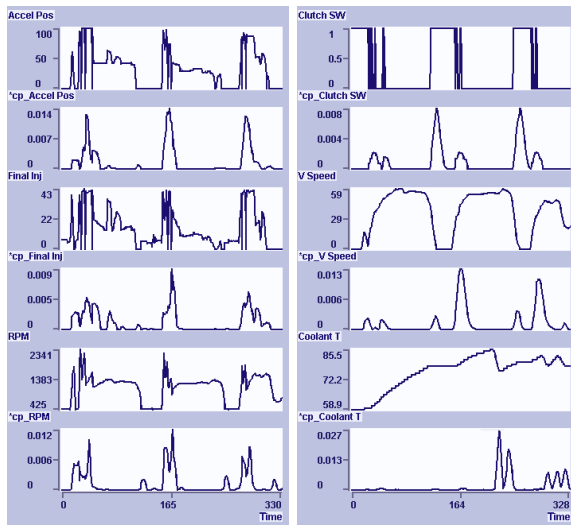


図5 6つの変数についての生データ(1,3,5段め)と対応する変化度(2,4,6段め)

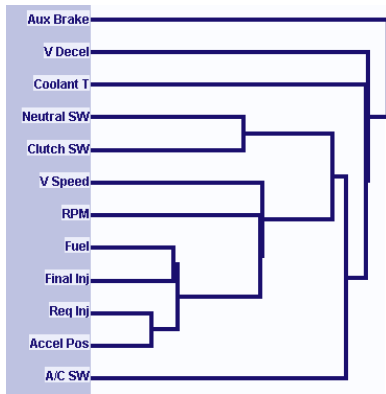


図6 12変数のクラスタリングを示すデンドログラム

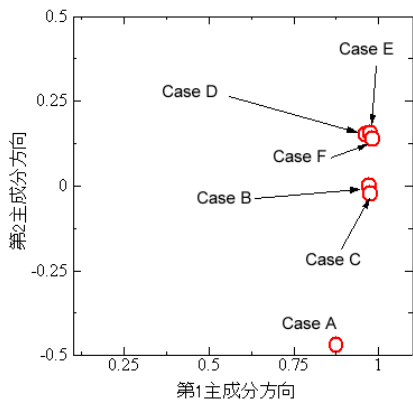


図7 データセットA-Fをプロットした図




図8 データセットA-Fのクラスタリング

の一つの見方であって、これ一つですべてをまかなうものではない。現状で欠けている部分(捨象されている)部分については、手法自体を拡張するか、補完的な手法と併用することが現実的には必要になる。具体的には以下のようなことが必要であろう。

- モードの考慮。因果関係が不変とは言っても、走行状態や何らかのモードで区間を区切って扱うことは、詳細な比較のためには有用と考えられる。
- 変化の重みづけ。今は、わずかな変化でもそれが全区間の中で相対的に大きければ顕著とみなすが、他のデータセットの同じ変数の変化との相対的なスケールの差も考慮するべきである。

5. まとめ

異種多変量の時系列によって記述される動的システムについて、障害解析の目的で、変化点関連度を使ってシステムの状態(正常・異常など)を評価したり比較する方法を提案した。いくつかの課題を解決することで、実際の故障解析への利用が可能である。

参考文献

- 1) 井手剛, 井上恵介: 非線形変換を利用した時系列データからの知識発見, 日本ソフトウェア学会データマイニング研究会(投稿中)(2004).
- 2) 尾崎統, 北川源四郎: 時系列解析の方法, 朝倉書店(1998).
- 3) 福田剛志, 森本康彦, 徳山豪: データマイニング, 共立出版(2001).
- 4) Basseville, M. and Nikiforov, I.: *Detection of Abrupt Changes*, Prentice Hall, Englewood Cliffs, New Jersey (1993).
- 5) Yamanishi, K. and Takeuchi, J.: A Unifying Framework for Detecting Outliers and Change Points from Non-Stationary Time Series Data, *Proceedings of the Eighth ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, pp. 676-681 (2002).
- 6) Hirano, S. and Tsumoto, S.: Mining similar temporal patterns in long time-series data and its application to medicine, *Proceedings of 2002 IEEE International Conference on Data Mining (ICDM 2002)*, IEEE, pp. 219-226 (2002).
- 7) Ghil, M., Allen, M. R., Dettinger, M. D., Ide, K., Kondrashov, D., Mann, M. E., Robertson, A. W., Saunders, A., Tian, Y., Varadi, F. and Yiou, P.: Advanced Spectral Methods for Climatic Time Series, *Reviews of Geophysics*, Vol. 40, pp. 1-41 (2002).
- 8) Moskvina, V. and Zhigljavsky, A.: An Algorithm Based on Singular Spectrum Analysis for Change-Point Detection, *Communications in Statistics—Simulation and Computation* (2003).