

## 時系列データからの汎用的異常検知手法の提案とその性能評価

荒木 英人<sup>†</sup>, 村川 正宏<sup>††</sup>, 小林 匠<sup>††</sup>, 樋口 哲也<sup>††</sup>,  
久保田 一<sup>†</sup>, 大津 展之<sup>††</sup>

<sup>†</sup> 千葉工業大学 <sup>††</sup> 産業技術総合研究所

多チャンネルの時系列データからの異常検知は、時系列データ源の状態や変化を検知する上で重要である。そこで我々は多チャンネルの時系列データから高次局所相関に基づいた特徴量を抽出し、抽出した特徴量より異常の検知を行う。普段頻繁に得られるデータを正常パターンとして、主成分分析を行うことでそのパターンの成す正常部分空間を抽出する。得られた空間からの逸脱度を異常値として定義し、この値の多寡で異常を検知する。本手法の性能評価のため、心電図データを対象として、異常検知性能の評価量にF値を用い、従来手法と比較した。その結果、提案手法の優位性を示すことができた。

## Proposal of general-purpose abnormality detection method for time-series data and its performance evaluation

Hidehito ARAKI<sup>†</sup>, Masahiro MURAKAWA<sup>††</sup>, Takumi KOBAYASHI<sup>††</sup>, Tetsuya HIGUCHI<sup>††</sup>,  
Hajime KUBOTA<sup>†</sup>, and Nobuyuki Otsu<sup>††</sup>

<sup>†</sup> Chiba Institute of Technology

<sup>††</sup> National Institute of Advanced Industrial Science and Technology(AIST)

Abnormality detection in multi-channel time-series data is important for detecting and understanding changes of states in the source of the data. We propose a method for automatically detecting abnormality by using correlation-based features of multi-channel time-series data. In general, the feature vectors for normal patterns, which occur frequently in time-series, form the low-dimensional subspace in the feature space. The proposed method exploits the subspace by PCA and defines the abnormality as deviation from the subspace. In the experiment of abnormality detection in electrocardiogram, the proposed method outperformed conventional methods in terms of F-measure.

### 1 はじめに

多チャンネル時系列データからの異常検知は、データ源の異常状態などの状態変化を知る上で重要である。例えば、医療現場では一般に時系列である患者のバイタルデータの異常を検知することで、疾患の有無を調べる。しかしながら、従来の異常検知手法では主に単チャンネルのみを対象としており<sup>1)</sup>、多チャンネルの時系列データを効率的に扱う手法は少ない。また、各種応用分野における異常検知手法も開発されているが、その問題に対する事前知識は不可欠であり、汎用的ではない。

そこで我々は多チャンネルの時系列データの相関情報に注目し、高次局所自己相関特徴 (Higher-order Local AutoCorrelation ; HLAC)<sup>2)</sup>を用いた、データ源に対する詳細な事前知識を必要としない時系列データの異常検知手法を提案する。正常なデータは一般にその発現頻度が大きいことか

ら、本稿では異常 (Abnormality) を正常ではない (Unusualness) 事象と定義する。ここでは主成分分析を適用することで、そのようなパターン分布の大部分を占める正常パターンの分布を近似する部分空間を形成する<sup>3)</sup>。この部分空間を以下では正常部分空間と呼び、この正常部分空間からの逸脱度を異常値として定義して、この値の多寡で異常を検知する。

本手法の性能評価のため、心電図データを用い、比較対象を多チャンネル時系列データを扱うことのできる従来手法として部分空間法を用いる手法と、ARモデルを用いた手法との比較を行った。異常検知性能の評価量として医師が実際に付与した異常個所に対するF値を算出し、提案手法の優位性を示すことができた。

## 2 提案手法

本提案手法は正常パターン分布の学習と異常検知の大きく2つの段階に分かれている。まず、第1段階の学習においては、多次元時系列信号の特徴として高次局所自己相関特徴を抽出し、パターンの成す正常部分空間を抽出する。処理の流れは図1(a)に示すように、特徴の抽出、特徴ベクトルの正規化、主成分分析、正常部分空間の形成となる。次に、第2段階の異常検知においては、第1段階で抽出した正常部分空間を用いて、毎時刻得られる時系列信号に対して異常検知を行う。処理の流れは図1(b)に示すように、特徴の抽出、正常部分空間の直交補空間への射影に基づく異常検知指標の算出、異常の判定から成る。以下各処理の詳細について述べる。




図1: 異常検知のながれ

### 2.1 高次局所自己相関特徴

$N$  次自己相関関数は、 $N$  個の変位に対し

$$r_f(\tau_1, \dots, \tau_N) = \int_{-\infty}^{\infty} f(t)f(t+\tau_1)\cdots x(t+\tau_N)dt \quad (1)$$

で定義される。変位の範囲をある局所領域に限定したものが、高次局所自己相関<sup>2)</sup>である。本手法においては、多チャンネルの時系列データから高次局所自己相関<sup>2)</sup>に基づいて特徴を抽出する。ここでは、2チャンネルの時系列データに対する $n$ 次までの局所自己相関特徴を考える。図2の左枠内の $\tau$ は相関をとる時間間隔（以下、相関幅と表記する）を表し、右の枠内の数字は特徴を計算する際の積算回数を表す。1つの相関パターンから得られる特徴量をベクトルの一要素とし、パターンの数と同じ次元数の特徴ベクトルを生成する。

2次までの局所自己相関特徴を考える場合、変位は2個までであるため、ある3サンプル間の相関までを考慮すればよい。よって、任意の $n$ チャンネルのパターンを考える場合、3チャンネルまでの




図2: 2次の局所相関パターン例

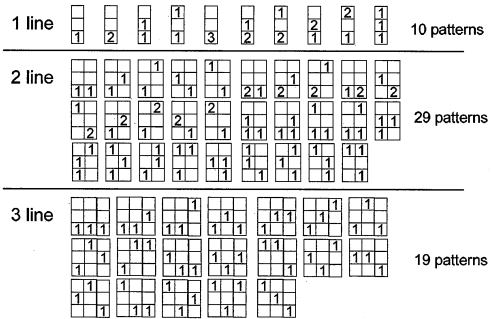


図3: 2次までの全相関パターン

相関パターンを数え上げた後、任意のチャンネルからどのチャンネルを選ぶかの組み合わせを計算すれば、任意の $n$ チャンネルに対するすべての相関パターンを得ることができる。3チャンネルまでのパターンは局所領域を過去の2時刻までに限定すると図3となる。この結果、任意の $n$ チャンネルのパターン数 $p$ は

$$p = 10 \times_n C_1 + 29 \times_n C_2 + 19 \times_n C_3 \quad (2)$$

となる。例えば、2チャンネルの時系列データに対する2次までの相関パターン数は $10 \times 2 + 29 \times 1 = 49$ であり、局所自己相関特徴で生成される特徴ベクトルは49次元となる。

### 2.2 部分空間法

時系列データ中の正常パターンはその出現頻度が高いことから、生成された特徴ベクトルは特徴空間内で、ある限定された領域に集中して分布することになる。ここでは、そのような分布を部分空間により近似し、正常部分空間を抽出する。

まず、入力時系列データから算出される特徴ベクトルの各要素が、平均0分散1になるように正規化を行う。これは特徴ベクトルの要素はより高次の相関量になるに従い信号の積算回数が増える

為、主成分分析において高次の相関量に強い影響を受けにくくするためである。正規化された特徴ベクトルを新たに  $\hat{x}(t)$  とする。特徴ベクトルに主成分分析を適用することで、正常部分空間を張る基底ベクトルを得る。これは、正規化された特徴ベクトルの相関行列

$$R_{\hat{x}} = \frac{1}{t_2 - t_1 + 1} \sum_{t=t_1}^{t_2} \{\hat{x}(t)\hat{x}(t)^T\} \quad (3)$$

の固有値問題を解くことにより求められる。ここで、 $t_1$  は選定された学習区間の開始時刻、 $t_2$  は学習区間の終了時刻である。

$$R_{\hat{x}}U = U\Lambda \quad (4)$$

ここで、 $U$  は固有ベクトルを列とする行列であり、 $\Lambda$  は固有値を対角要素とする対角行列である。正常部分空間の次元数  $K$  は累積寄与率

$$\eta_K = \frac{\sum_{i=1}^K \lambda_i}{\sum_{i=1}^p \lambda_i} \quad (5)$$

により決定される。このとき、正常部分空間の次元数  $K$  は

$$\eta_K \geq C \quad (6)$$

を満たす最小の整数とする。ただし、 $C$  は任意の定数である。ここでさらに、 $U_K$  を  $K$  番目に大きな固有値までに対応する固有ベクトルを列にもつ行列とする。

### 2.3 異常値の定義

正規化された特徴ベクトルの正常部分空間からの逸脱度を異常検知指標とする。具体的には、特徴ベクトルと正常部分空間との間の距離を指標とする。この時、正常部分空間への射影子  $P$  は

$$P = U_K U_K^T \quad (7)$$

となることから、入力時系列内で時刻  $t$  での異常検知指標  $d(t)$  は

$$d(t) = \sqrt{|\hat{x}(t)|^2 - \hat{x}(t)^T U_K U_K^T \hat{x}(t)} \quad (8)$$

となる。以下では、この  $d(t)$  を異常値とよび、この異常値がある閾値を超えた時に異常と判定する。

### 2.4 異常の判定

本手法では、異常検知指標から異常状態の判定を行うための閾値を

$$\text{Threshold} = \mu_d + \alpha \sigma_d \quad (9)$$

のようにして求める。ここで、 $\mu_d$  は正常パターン分布の学習に用いた区間における平均値、 $\sigma_d$  は標準偏差で、 $\alpha$  は任意の係数である。




図 4: 対象の心電図データとその異常値

## 3 実験

本提案手法の有効性を検証するため、MIT-BIH Arrhythmia Database<sup>1</sup>に含まれる心電図データを用いて、異常検知実験を行った。また、多チャンネルの時系列データを扱うことのできる2つの従来異常検知手法も適用し、F値<sup>4</sup>)を用いて異常検知性能の比較を行った。本実験に用いたデータは2チャンネル、約35~50秒間(12500~18000[samples])の6種類の心電図データで、サンプリング周波数は360[Hz]である。

### 3.1 異常検知結果

6種類のデータのうちの1つに本手法を適用した場合の異常値の結果を図4に示す。このデータは2チャンネル、約35秒間(12500[samples])の心電図データである。このデータには医師が異常と判断した区間が6箇所存在する。このデータから、移動平均時間幅  $T = 5$ [samples]、相関幅  $\tau$  を4[samples]として特徴量を抽出し、学習にはこのデータのすべての区間を用いた。正常部分空間の次元数  $K$  は式(6)の定数  $C$  を0.99として決定した。図4(a)は第1チャンネル、図4(b)第2チャンネルの心電図データであり、図4(c)は本手法により得られた異常値である。また、図4(c)の破線は閾値であり、太棒で囲まれた区間は、医師により異常と診断された区間である。

図より、正常パターンの学習区間に異常区間が含まれているにもかかわらず、医師が異常としたすべての区間において異常値が閾値を超えており、異常と判定されていることがわかる。

<sup>1</sup> MIT-BIH Arrhythmia Database

<sup>2</sup> <http://www.physionet.org/physiobank/database/mitdb/>

### 3.2 異常検知性能の比較

異常検知性能を表す評価量として F 値を用いる。心電図データには一拍ごとに医師の診断結果が付与されているため、一拍(約 300[samples])ごとの区間に区切り、区間内の異常値の最高値をその区間の代表値とする。

F 値は、R:医師の判断と一致した異常の数、N:実験より異常と判定した異常の数、C:医師が判断した異常の数であるとき

$$F = \frac{R}{1/2(N+C)} \quad (10)$$

のようにして得られる。F 値の最大値は 1 であり、この値が大きいかほど性能が良いことを意味する。

この評価量を用いて、Moskvina and Zhigljavsky の手法<sup>5)</sup>と、AR モデルを用いた手法と本手法との異常検知性能の比較を行った。ここで、Moskvina and Zhigljavsky の手法は、特徴ベクトルに

$$\mathbf{x}(t) = [f(t)f(t+\tau)f(t+2\tau)g(t)g(t+\tau)g(t+2\tau)] \quad (11)$$

として、本手法と同様に部分空間法による異常検出を行っている。AR モデルは 3 次の AR モデルとして、AR 係数を推定したのち、AR モデルの出力と実際の信号の二乗誤差値を異常値として、異常検知を行った。

図 4 のデータに対し、提案手法の正常部分空間形成時の累積寄与率を 0.9, 0.99, 0.999, 0.9999 とし異常検知実験を行い、閾値の任意の重み  $\alpha$  を 1~15 まで変化させた時の F 値を図 5 に示す。また、6 つの心電図データに対する F 値の従来手法との比較を図 6 に示す。図 5 において、提案手法の F 値の最高値は高い値となっており、良好な異常検知性能を示している。図 6 より、本手法はほぼ常に 2 つの従来手法の F 値を上回っており、本手法の有効性が示された。

### 4 結論

多チャンネルの時系列データに対する高次局所自己相関特徴を提案し、主成分分析を用いた時系列データからの異常検出方法を提案した。提案手法を 2 チャンネルの心電図データの異常検知に適用した結果、事前知識を用いず、全区間で学習することで、医師が異常と判定した区間を適切に自動検知することに成功した。また、F 値を用いた異常検知性能の比較により、従来手法に対する本手法の有効性が示された。今後は、正常パターンの統計的性質の変化に対応するため、正常部分空間




図 5: F 値の比較




図 6: 6 つの心電図データに対する F 値の比較

の学習と異常検出を同時に行うオンライン学習<sup>3)</sup>も検討する。

本研究は、NEDO インテリジェント手術機器研究開発事業により実施した。

### 参考文献

- 1) Eamonn Keogh, Jessica Lin, Ada Fu: "HOT SAX: Finding the Most Unusual Time series Subsequence: Algorithms and Applications", in Proc. of the 5th IEEE Int'l Conf. on Data Mining, pp440-449, (2004)
- 2) 大津展之: 「パターン認識における特徴抽出に関する数値的研究」, 電子技術総合研究所研究報告, 第 818 号, 電子技術総合研究所, (1981)
- 3) Takuya Nanri, Nobuyuki Otsu: "Unsupervised Abnormality Detection in Video Surveillance", Proc.IAPR Conference on Machine Vision Application, pp.574-577, (2005)
- 4) Christopher D.Manning, Hinrich Schütze: Foundations of Statistical Natural Language Processing, p267-271, The MIT Press, (1999)
- 5) Valentina Moskvina, Anatoly Zhigljavsky: "An Algorithm Based on Singular Spectrum Analysis for Change-Point Detection", Communications in Statistics Simulation and Computation, Vol.32, No.2, pp.319-352, (2003)