

スパース構造学習による  
センサー・データの変化点検出と異常解析

井手 剛

Change-point detection and  
failure analysis of sensor data using sparse structure learning

Tsuyoshi Idé

産業上重要なセンサー・データの異常解析問題では、ダイナミックに変動する多変数系の解析を要求されることが多い。そのような状況で実用に足る解析技術は極めて乏しいのが現状であった。本論文でわれわれは、スパース構造学習という技術を使って、データ生成源に生じた変化を検出し（変化点検出）、さらに、それにどの変数がどの程度寄与しているかを表すスコアを計算する手法を提案する。われわれは、自動車のシミュレーション・データを用いて、従来技術では検出が困難であった異常を検知できることを示す。

Most of the practically important failure analysis problems require advanced technologies for multivariate sensor data that is highly correlated and dynamic. In spite of its industrial importance, however, few methodologies are known for handling such particular types of data. In this paper, based on sparse structure learning, we propose a method for detecting essential changes of the system (change-point detection) and for scoring the contribution of the individual variables to the changes. Using realistic automobile data, we demonstrate the utility of our method in a failure analysis task that has been known to be hard even for experienced engineers.

Key Words &amp; Phrases : 変化点検出, スパース構造学習, センサー・データ

Change-point detection, sparse structure learning, sensor data

## 1. はじめに

近年のセンシング技術、および情報技術（IT: Information Technology）の発展に伴い、さまざまな産業分野でセンサー・データの利用が考えられるようになってきた。物理的なシステムがかかわるすべての産業分野で、計測と制御は基本的な重要性を持つ。それゆえ、センサーで取得した物理データに何らかの解析を行い、それを実ビジネスに役立てることは非常に長い歴史を持つ。例えば、本格的なデータ解析技術の産業応用の初期の代表的な成果である赤池、中川らによるセメントキルン制御の事例が成書として出版されたのは1972年のことである [1]。

しかし、ここ数年のITの発展は、センサー・データ解析をめぐる従来の想定を多く塗り替えつつある。第1に、センシング技術の発展により、センシングとデータ伝送にまつわるコストが劇的に低下した。これを象徴的に表すのが Smart Dust [2] によるセンサー・ネットワークの実現であろう。第2に、ITの発展により、データ蓄積にまつわるコストが劇的に

低下した。テラバイトを超えるようなデータを蓄積することはかつて夢の世界であったが、今や民生品のコンピューターでさえ、その程度のストレージを備えるものは珍しくない。第3に、企業内のIT基盤が整備された結果、情報さえ与えられれば、「ダッシュボード」のような形でレポートを行うことが容易になった。

このような状況変化に伴い、多くの産業分野において、センサー・データの活用、さらに、センサー・データを用いた新しいビジネスモデルの創出に興味を持たれている。例えば、建設機械メーカーの場合、もし、個々の機器をモニタリングし、データを適切に解析できれば、新しい形態の保守サービスが実現できるかもしれない。

しかしながら、後に見てゆくように、われわれの手元にある解析技術は、現在取得可能なセンサー・データを網羅するには程遠い。比喩的に述べれば、古典的な技術で何らかの有用な知見を見いだせると考えられるのは、全センサー・データのほんの1%といったところで、残りの99%は活用されることなく捨てられている。解析のための有効な手段を欠いているからである。

提出日:2010年3月18日 再提出日:2010年3月26日

逆に言えばこのことは、実用的な解析技術の開発が、新しいビジネスを直ちに創出するだけのインパクトを持っているということを意味する。これは、機械学習という新しい技術をベースにした情報検索の技術が、Webの世界に巨大なビジネス機会を生み出した事実と対比できよう。あるいはさらに古く、半導体技術が、エレクトロニクス産業を生み出したという事実に対比できよう。われわれはおそらく、トランジスタの発明前夜にいる。この認識が、われわれをしてセンサー・データ解析に注力させている理由である。

本論文では以下、センサー・データの一般的な特徴をまとめ、可能な研究課題、とりわけ産業上重要な異常検知技術に関する従来技術を概観する。その中で、変数同士の複雑な絡み合いを解きほぐし、いわば小さな部分系に分割する「スパース構造学習」という手法が応用上大きな重要性を持っていることを指摘する。そしてその手法を用いて、多変数のセンサー・データの変化点検出問題への解を与える。最後に、機械システムの変化点検出問題への、われわれの手法の適用例を述べる。

## 2. センサー・データに対する解析技術の現状

本節では、センサー・データ解析において産業上最も重要なテーマである異常検知に的を絞って既存技術を概観する。異常検知技術に関するより網羅的なサーベイに関しては文献 [3] などを参照されたい。

以下、センサー・データを、温度や湿度、あるいは加速度などの物理量を時系列的に測定したものと想定しておく。もちろん、物理量以外にも、通過車両台数のような非物理量でも構わない。本質的なのは、内部のデータ生成機構が未知な系から、時系列的に数値データが取得されるという点である。

### 2.1 異常検知問題の分類

センサー・データの異常検知の問題設定は多岐にわたるが、現在多く研究されているのは次のシナリオである。

- 外れ値検出 (outlier detection)
- 変化点検出 (change-point detection)
- 異常部位検出 (discord discovery)

外れ値検出は、1点の観測値の外れ度に着目する。突発的に高い温度が検出された、などがその例である。

変化点検出は、時系列データを生み出す背後のモデルの変化に着目する。例えば、ある時点から機器が特異な振動を始めたとする。仮に観測値自体がある正常範囲に入っていたとしても、これを何らかの異常の兆候として検出したい場合もあろう。

異常部位検出問題では、1本ないし複数の時系列の一部のある長さの窓で切り取り、その部分時系列の、平均的な振る舞いからの外れを調べる。例えば、心臓の鼓動を記録した時系列において、時折、普段と異なる拍動のパターンが記録されるとする。そのような部位を自動的に検出できれば、例えば心筋梗塞の診断に役立つかもしれない [4]。

### 2.2 変化点検出問題

さて、上記の問題設定の中で、変化点検出問題にさらに的を絞ろう。変化点検出は統計学の分野で長い間研究されてきた問題である。典型的なアプローチは、データの生成モデルを過去のデータから学習し、そのモデルが現在のデータにどのくらい当てはまるかの度合いを求め、その大小から変化の有無を調べることである [5]。

今、データとして、時刻  $t$  までに、 $M$  次元のベクトル列  $\mathbf{x}^{(1)}, \mathbf{x}^{(2)}, \dots, \mathbf{x}^{(N)}$  が観測されたとしよう。 $M$  個の次元のそれぞれが変数(センサー)に対応する。この時、何らかの方法で、データを生成する確率分布  $p(\mathbf{x}|t)$  を求めることができる。例えば正規分布 (Gaussian)

$$p_G(\mathbf{x}) = \frac{|\Lambda|^{-\frac{1}{2}}}{(2\pi)^{\frac{M}{2}}} \exp \left\{ -\frac{1}{2} (\mathbf{x}-\boldsymbol{\mu})^T \Lambda (\mathbf{x}-\boldsymbol{\mu}) \right\} \quad (1)$$

を仮定して、モデル・パラメーター (今の場合は平均  $\boldsymbol{\mu}$  と精度行列  $\Lambda$ ) をデータから最尤推定で求めることができる<sup>\*1</sup>。あるいは、カーネル密度推定のようなノンパラメトリック・モデルで  $p(\mathbf{x}|t)$  を推定することも多い。その場合、

$$p_{NP}(\mathbf{x}) = \sum_{n=1}^N c_n K(\mathbf{x}, \mathbf{x}^{(n)}) \quad (2)$$

のようなモデルとなる。ただし  $c_n$  はデータから決められる係数で、 $K(\mathbf{x}, \mathbf{x}^{(n)})$  は入力データ点と第  $n$  番目のサンプルとの間のいわゆる核関数である。ガウシアン・カーネルなどが広く使われている。

通常の変化点検出の手続きでは、対数尤度比

$$s(t) = \sum_{n=1}^N \ln \frac{p(\mathbf{x}^{(n)}|t)}{q(\mathbf{x}^{(n)})} \quad (3)$$

を求め、これがある値を超えると変化が生じたと判断する。ただし  $q(\cdot)$  は、基準となる分布である。産業上の応用では、 $q(\cdot)$  を正常時のデータの分布と設定することで、不具合の発生の有無を検定することができる。

尤度比は、ネイマン・ピアソンの補題の意味で最適な統計量であること、その対数が漸的にカイ2乗分布に従うことなど、顕著に優れた性質を持ち、変化点検出理論の確固たる基盤をなしている [5]。しかし実用上は、後述のさまざまな問題点があり、文脈に応じてさまざまな工夫がされてきた。

最近の代表的な研究を挙げると、逐次忘却型自己回帰モデルによるもの [6]、逐次的主成分分析によるもの [7] [8]、状態空間モデルの同定によるもの [9]、密度比の直接推定によるもの [10] などが挙げられる。

<sup>\*1</sup> 多変量正規分布の定義や最尤推定、あるいはノンパラメトリックな密度推定法などの基礎事項については文献 [15] などを参照されたい。

### 2.3 従来技術の困難

上に述べたように、伝統的な変化点検出の手法は実用上いろいろな困難を抱えている。まず第1に、尤度比に対してこれまで導出されてきた漸近分布の多くは、実際上そのままではほとんど役に立たないという点である。これは現代のセンサー・データでは、サンプル数  $N$  は事実上ほとんど無制限に大きくできるので、漸近分布に従って設定された危険域があまりにも厳格になりすぎるためである。

第2に、変数の数  $M$  が大きくなると、分布推定自体が極めて難しくなることである。例えばモデルとして、(1) 式の変量正規分布を考えよう。分布推定のためには、共分散行列もしくはその逆行列である精度行列を推定する必要があるが、実はこれが簡単ではない。実際のシステムでは、変数にはしばしば冗長性があり、従って共分散行列は通常ランク落ちをするからである。そうでなくとも変数が数10を超えると、数値的にランク落ちをすることはよくある。仮にランク落ちを免れたとしても、2次の統計量としての共分散はノイズに非常に脆弱であり、ダイナミックに変動するデータに対して正しい値を計算するのは非常に難しいことが知られている。正規分布以外のモデルではますますその傾向は強まる。その結果、(3) 式のような変化度のスコアリングでは、システムの部分的な変化に乱されて、誤警報が頻発することになる。

第3に、(3) 式のような変化度の定義では、ユーザーのアクションにつなげにくいという点がある。すなわち、仮に機器に異常が発生し、それが変化点として検知されたとする。この場合、次に必要なのは、その変化の原因についての情報である。そのためには、どの変数がその変化にどれだけ寄与しているかという情報が有用であるが、(3) 式からそれをどう計算するかは自明ではない。

上記の困難は、いずれも多変量のダイナミック・システムの解析にかかわる本質的な問題であり、その解決は非常に困難だと思われてきた。しかし、次節で見る通り、ごく最近開発されたスパース構造学習の技術を用いると、これらの問題を回避できるのである。

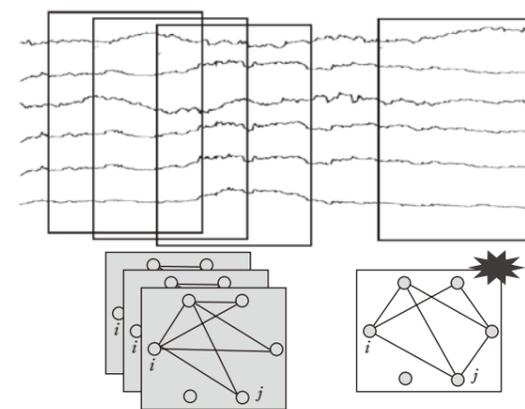


図1. スパース構造学習による変化点検出の説明。センサー・データの内部構造をスパースなグラフとして逐次求め、その変化を検知する。

## 3. スパース構造学習

図1に、スパース構造学習による変化点検出のイメージ図を示す。構造学習とは、変数(センサー)同士の本質的な依存関係をデータから見いだすことを指す。依存関係を見いだすということをより正確に述べれば、「変数を頂点とする(重み付き)グラフを求めること」ということになる。依存関係がある変数同士の間には辺が張られるが、そうでない場合には辺は張られない。従って、スパースな(疎な)構造学習といった場合、真に本質的な依存関係にのみ辺があるようなグラフを求めるのが目標になる。言い換えると、非本質的と見なされる依存関係はある程度割り切ることで、システムのモジュール構造を自動的に見いだす。まさにこの、「自動モジュール分割機能」こそが、いわゆる次元の呪いに打ち勝つ鍵になる。

### 3.1 グラフィカル・ガウシアン・モデルと構造学習の古典技術

スパースな構造をどのように求めるか説明する前に、より正確なグラフの定義を与える。われわれは、グラフィカル・ガウシアン・モデル (GGM) [11] に従ってグラフを定義する。GGM ではデータの背後に多変量正規分布が想定され、その精度行列  $\Lambda$  がグラフの隣接行列と同一視される。従って、スパースな構造を求めるということは、スパースな精度行列をデータから求めるということと等価である。

GGM の枠内での構造学習自体は、共分散構造解析という名前で古くから知られていた。共分散構造解析では、式(1)における精度行列  $\Lambda$  が、標本共分散行列  $\mathbf{S}$  の逆行列として

$$\Lambda = \mathbf{S}^{-1}, \quad \mathbf{S} \equiv \frac{1}{N} \sum_{n=1}^N \mathbf{x}^{(n)} \mathbf{x}^{(n)T} \quad (4)$$

のように書けるという事実が出発点である(以後、個々の変数の平均は0、分散は1にあらかじめ規格化されていると仮定する)。しかし先述のように、標本共分散行列  $\mathbf{S}$  は多変量系ではほとんど常にランク落ちしており、実用上は出発点においてすでに破綻しているといえる。

### 3.2 ラプラス事前分布によるMAP推定

われわれもGGMに基づく構造学習を志向するが、上記の従来技術の限界に基づき、解くべき問題を拡張する。すなわち、式(1)を、精度行列  $\Lambda$  が与えられた時の条件付き分布  $p_G(\mathbf{x}|\Lambda)$  と見なし、 $\Lambda$  については、事前分布として、要素ごとに同一のラプラス分布を付す。すなわち、

$$p(\Lambda) = \prod_{i,j=1}^M \frac{\kappa}{2} \exp(-\kappa |\Lambda_{i,j}|) \quad (5)$$

である。この式から明らかに分かるように、この事前分布は、 $\Lambda$  の要素の値を0付近に束縛する効果を持つ。

そうしてGGMの隣接行列  $\Lambda^*$  を、事後確率最大 (MAP:

Maximum a posteriori) 原理 [12] に従って求める。

$$\Lambda^* = \operatorname{argmax}_{\Lambda} \left\{ \ln p(\Lambda) \prod_{n=1}^N p_G(\mathbf{x}^{(n)} | \Lambda) \right\} \quad (6)$$

詳細は省くが、これは行列  $\Lambda$  に対する凸最適化問題となることが知られており、効率のよい解法も存在する [13]。

やや意外なことであるが、(5) 式のような事前分布を設定することで、MAP 解  $\Lambda^*$  の行列要素の多くが厳密にゼロになることが知られている。疎なグラフが自動的に得られるということである。このような「解のスパース化」を行う技法の発見は、ここ 10 年の統計学および機械学習研究の金字塔のひとつであり、本研究もその成果を直接受け継ぐものである。

#### 4. 構造変化のスコアリング

さて、上記のスパース構造学習により、図 1 における時間軸上の 2 点の近傍に置いた窓内のデータに対応するスパースな構造が得られた。それらを添え字 A と B で区別しよう。GGM の文脈ではこのことは、データを生成する 2 つの確率モデル  $p_A(\mathbf{x})$  と  $p_B(\mathbf{x})$  が得られたのと同義である。われわれは両者を比較して、どの変数がどれだけその変化に寄与したかを表すスコアを計算したい。

情報理論的に、確率分布同士の距離を測る最も自然な尺度は、Kullback-Leibler (KL) 距離である。しばらくの間、特定の変数  $i$  に着目しよう。量

$$d_i^{AB} \equiv \int d\mathbf{z}_i p_A(\mathbf{z}_i) \int d\mathbf{x}_i p_A(\mathbf{x}_i | \mathbf{z}_i) \ln \frac{p_A(\mathbf{x}_i | \mathbf{z}_i)}{p_B(\mathbf{x}_i | \mathbf{z}_i)} \quad (7)$$

は、 $p_A(\mathbf{x}_i | \mathbf{z}_i)$  と  $p_B(\mathbf{x}_i | \mathbf{z}_i)$  との間の KL 距離の期待値を、分布  $p_A(\mathbf{z}_i)$  によって計算したものである。ただし、

$$\mathbf{z}_i \equiv (x_1, \dots, x_{i-1}, x_{i+1}, \dots, x_M)^T \in \mathbb{R}^{M-1} \quad (8)$$

と定義した。式 (7) において A と B を入れ替えることにより  $d_i^{BA}$  の定義も得る。

$d_i^{AB}$  および  $d_i^{BA}$  は、第  $i$  番目の頂点の周りの近傍グラフの変化を、KL 距離の意味で、すなわち、エントロピーの差の観点で定量的に測る指標である。この量が大きければ大きいほど、 $x_i$  が絡む変化は大きくなる。従って、第  $i$  変数の異常度もしくは変化度を次のように定義することができる。

$$s_i = \max \left\{ d_i^{AB}, d_i^{BA} \right\} \quad (9)$$

これを具体的に計算するには、式 (7) の積分を実行しなければならないが、われわれのモデルではそれは解析的に実行可能である。式の詳細は省くが ([14] 参照)、その結果によれば、異常度  $s_i$  が、(1) 変数  $x_i$  の近傍のグラフの次数

の変化、(2)  $x_i$  の近傍のグラフの辺の重みの変化、(3)  $x_i$  それ自身の分散の変化、という自然な解釈を持つ 3 つの項からなる。期待 KL 距離という情報理論の産物からこのような直感的に自然な異常度を導けたことは興味深い。

#### 5. 事例

ここでは、自動車のシミュレーション・データを元に、前節で説明した技術の適用例を紹介する。

##### 5.1 データの説明

ここでは、あるプロトタイプの自動車の多数回の走行データに基づいて人工的に生成したシミュレーション・データについて、相関異常のスコアリングを試みる。もともとこのデータは、急ブレーキ時の挙動を調べる目的で生成されたため、時系列は高度に非定常であり、データの主要部を時系列的に予測できるモデルを学習することは困難である。

データは時間軸上の正常時と目される状態で 79 カ所、異常を含む状態での 20 カ所の窓により取られた。それぞれの窓はおおよそ  $N=150$  点を含み、変数の数は  $M=44$  である。

図 2 はある特定の走行において、 $M=44$  の中の 4 つのセンサーについて変数対ごとの散布図を示したものである。注意深く図を見ると、 $x_{24}$  と  $x_{32}$  の散布図が、正常時は強い逆相関を呈しているのに対し、異常時にはそれが失われていることが分かる。これは実際に  $x_{24}$  の配線ミスに起因するものであるが、散布図における軌跡の複雑さや不安定性を見れば、これを検知することの難しさが了解される。実際、Wishart 分布理論に基づく相関係数の仮説検定の手続き [15] を用いた場合、常識的な棄却域の値に対し、相関係数行列のほとんどすべての行列要素に対して、参照データとの同一性が棄却されてしまい、異常変数の同定どころの話ではない。

##### 5.2 異常検知性能の評価

上記のデータについてわれわれの手法の異常検知性能を調べた。結果をいわゆる ROC 曲線 (Receiver Operating Characteristic curve) として図 3 に示す。ROC 曲線は、見逃しの少なさと誤警報の少なさの双方を視覚的に示すものであり、その曲線の下面積が 1 に近いほど (すなわち、左上に曲線が張り付くほど) 性能がよい。完全にランダムに異常判定をした場合は、図に点線で示したような右上がりの直線になる。図では、われわれの手法 (○) を、考え得る別手法と比較している。ラプラス事前分布のパラメータは  $\kappa=0.3N$  に選んだ。

比較したのはいずれも、何らかの意味でスパース構造学習に基づく手法である。△がすべての変数について、もっとも相関の高い 2 つを選ぶことでスパースな構造を実現したもので、ほかの□と×は、提案手法の○と同様、式 (6) により求めたスパース・グラフを使っている。先に述べたように、スパース性をまったく導入しない手法、例えば Wishart 分布に基づく共分散の 2 標本検定などを行うと、ほぼランダムな選択と変わらない結果になるので、ここでは比較の対象から外した。

図 3 において比較された手法の主たる相違は、異常度のスコアリングの方法である。○の提案手法は、(7) 式の期待平均 KL 距離を使ったが、×は  $p_A(x_i | \mathbf{z}_i)$  などの条件付き分布を使って尤度比を求め、それを異常度に読み変えたものである。一方、△と□は、論文 [16] で提案されたスコア指標を用いたものである。

図から、ラプラス分布を事前分布に付した MAP 推定によるスパース構造学習を、期待 KL 距離と組み合わせたものが最も優れた結果を与えていることが分かる。また、図 2 に示したような著しく強いノイズが含まれるデータに対しても、AUC 値 (ROC 曲線の下部の面積) にして 0.96 にも上る精度を示し

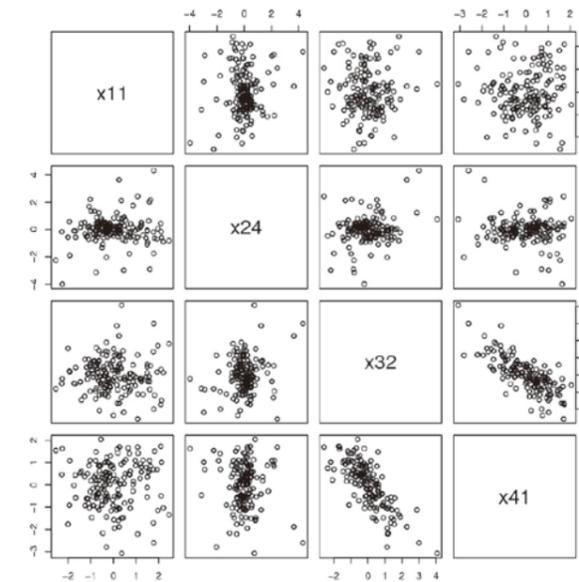
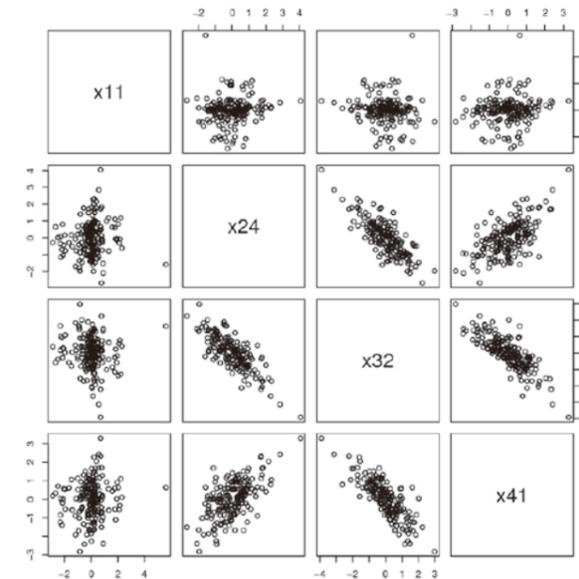


図 2. 自動車のシミュレーション・データの、変数対ごとの散布図 (一部)。上: 正常時第 10 番目のデータ、下: 異常時第 3 番目のデータ。

たのは特筆すべきことであると思われる。

今回のデータに含まれていたのは、センサーの配線ミスに関するものであった。配線ミスは変数同士の依存関係の変化に当然つながるため、今回のような、系の構造変化を検知する手法は非常に有効である。従来、強いノイズに頑強にそのような構造変化をとらえる手法は存在しなかったのだが、われわれの手法はそのハードルを越えることができたということである。

#### 6. まとめ

センサー・データの変化点検出問題に対する新しいアプローチを提案した。われわれの手法では、データの変化点は、グラフィカル・ガウシアン・モデルの変化として定義され、その変化に対する個々の変数の寄与度が、情報理論的に首尾一貫した指標で計算される。精度行列の要素にラプラス分布を付した MAP 推定を行うことで、スパースでなおかつ本質的な依存関係を残したグラフを得ることができ、そしてそれが、次元の呪いを避け、いわば系に隠されたモジュールを自動で見いだしていることに当たることを指摘した。

提案手法を使い、従来は極めて困難であった、ダイナミックで相関の強い (多重共線性の問題も深刻な) 系に対し、変化点検出および異常解析が非常に高い精度で実行できることを示した。

文中に述べたように、これから大量に取得されるようになるセンサー・データを活用する技術は、まだまだ成熟には程遠い。しかしここ数年の研究動向を見ると、近い将来、機械学習の分野で開発された技術を元にして何かの技術革新が起こる可能性が高い。その際、本論文で述べたような、潜在構造の振る舞いに着目する手法が有望であるように思われる。

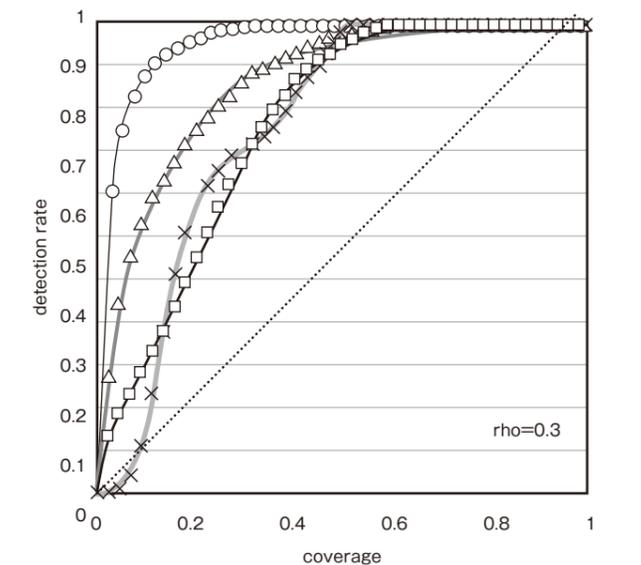


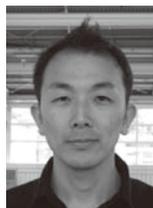
図 3. 別手法 (□, △, ×) に対する提案手法 (○) の比較 ( $\rho=0.3$ )。

## 謝辞

IBM 東京基礎研究所の高橋俊博研究員には、本論文の手法を IBM InfoSphere Streams 上に実装する際、多大な協力を得た。ここに謝意を表す。

## 参考文献

- [1] 赤池弘次, 中川東一郎: *ダイナミックシステムの統計的解析と制御*, サイエンス社 (1972).
- [2] B. Warneke, M. Last, B. Liebowitz, and K. S. J. Pister: "Smart Dust: Communicating with a Cubic-Millimeter," *Computer*, Vol.34, pp.44-51 (2001).
- [3] V. Chandola, A. Banerjee, and V. Kumar: "Anomaly detection: A survey," *ACM Computing Survey*, Vol. 41, No. 3, pp.1-58 (2009).
- [4] E. J. Keogh, J. Lin, and A. W.-C. Fu: "HOT SAX: Efficiently finding the most unusual time series subsequence," *Proc. of the 5th IEEE Intl. Conf. Data Mining*, pp. 226-233 (2005).
- [5] M. Basseville and I.V. Nikiforov: *Detection of Abrupt Changes*, Prentice Hall (1993).
- [6] K. Yamanishi and J. Takeuchi: "A Unifying Framework for Detecting Outliers and Change Points from Non-Stationary Time Series Data," *Proc. the Eighth ACM SIGKDD Intl. Conf. Knowledge Discovery and Data Mining*, pp.676-681 (2002).
- [7] T. Idé: "Knowledge Discovery from Heterogeneous Dynamic Systems using Change-Point Correlations," *Proc. of 2005 SIAM Intl. Conf. Data Mining*, pp.571-575 (2005).
- [8] T. Idé and K. Tsuda: "Change-point detection using Krylov subspace learning," *Proc. of 2007 SIAM Intl. Conf. Data Mining*, pp.515-520 (2007).
- [9] Y. Kawahara, T. Yairi and K. Machida: "Change-point detection in time-series data based on subspace identification," *Proc. of the 7th IEEE Intl. Conf. on Data Mining (ICDM 07)*, pp.559-564 (2007).
- [10] Y. Kawahara and M. Sugiyama: "Change-point detection in time-series data by direct density-ratio estimation," *Proc. of the 2009 SIAM Intl. Conf. on Data Mining (SDM 09)*, pp.389-400 (2009).
- [11] S. L. Lauritzen: *Graphical Models*, Oxford (1996).
- [12] C. ビショップ: *パターン認識と機械学習, 上*, シュプリンガー (2007).
- [13] J. Friedman, T. Hastie and R. Tibshirani: "Sparse inverse covariance estimation with the graphical lasso," *Biostatistics*, Vol.9, No.3, pp.432-441 (2008).
- [14] T. Idé, A. C. Lozano, N. Abe and Y. Liu: "Proximity-Based Anomaly Detection using Sparse Structure Learning," *Proc. of 2009 SIAM International Conference on Data Mining*, pp.97-108 (2009).
- [15] T. W. Anderson: *An Introduction to Multivariate Statistical Analysis*, 3rd. ed., Wiley-Interscience (2003).
- [16] T. Idé, S. Papadimitriou and M. Vlachos: "Computing Correlation Anomaly Scores using Stochastic Nearest Neighbors," *Proc. IEEE Intl. Conf. Data Mining*, pp.523-528 (2007).



日本アイ・ビー・エム株式会社  
IBM 東京基礎研究所  
アドバイザー・リサーチャー

井手 剛 Tsuyoshi Idé

### [プロフィール]

2000年にIBM 東京基礎研究所に入所、液晶工学の研究に従事。その後、データ・マイニングの研究に転じ、2004年頃から、センサー・データ解析のグループをリード。主に時系列データの異常解析技術に関する研究に従事。人工知能学会全国大会優秀賞(2004, 2006年)ほか受賞。博士(理学)。