

## 変化点検出を応用した時系列データからの 突発現象の前兆検出アルゴリズム

徳 永 旭 将<sup>†1</sup> 池 田 大 輔<sup>†2</sup> 中 村 和 幸<sup>†3</sup>  
樋 口 知 之<sup>†4</sup> 吉 川 顕 正<sup>†5</sup> 魚 住 禎 司<sup>†6</sup>  
藤 本 晶 子<sup>†7</sup> 森 岡 昭<sup>†8</sup> 湯 元 清 文<sup>†6</sup>

一般に、前兆現象は突発現象にそのものに比べて非常に目立ちにくく、その開始時刻は曖昧である。従来よく用いられてきた変化点検出法を適用した場合、このような微小で緩慢な変化は見逃されやすい。Tokunaga ら (2010) では、Ide ら (2005) の提案した特異スペクトル分析を応用した変化点検出法 (SST) を、多次元データを用いたアルゴリズム (MSST) へと拡張することで、鋭敏に前兆現象の開始時刻を推定できることを示した。MSST は、緩慢な変化も検出できる鋭敏な手法であるが、実データへの適用では誤検出が問題になる。本稿では、突発現象の大まかな開始時刻をあらかじめ検出し、さらに検出された時刻の前後で前兆現象の開始時刻と終了時刻を個別に探索することで、前兆現象を鋭敏に検出でき、かつ MSST 単体よりも誤検出を劇的に減少させることができることを示す。

### An Algorithm for Detecting Precursory Events from Time Series Data

TERUMASA TOKUNAGA,<sup>†1</sup> DAISUKE IKEDA,<sup>†2</sup>  
KAZUYUKI NAKAMURA,<sup>†3</sup> TOMOYUKI HIGUCHI,<sup>†4</sup>  
AKIMASA YOSHIKAWA,<sup>†5</sup> TEIJI UOZUMI,<sup>†6</sup>  
AKIKO FUJIMOTO,<sup>†7</sup> AKIRA MORIOKA<sup>†8</sup>  
and KIYOHUMI YUMOTO<sup>†6</sup>

In general, precursory events are observed as minute and less-visible fluctuations preceding an onset of massive fluctuations of extraordinary phenomena. Hence, existing change-point detection methods most likely overlook precursory events. Tokunaga, et al. (2010) extended the method for detecting the change-points, Singular Spectrum Transformation (SST) proposed by Ide, et al. (2005),

to the multivariable SST (MSST). Although MSST can detect minute changes, we have to reduce false positives because real world data includes non-stationary trends and measurement noise. In this paper, we propose the algorithm to detect precursory events in an off-line manner. Our algorithm consists of three kinds of change-point detection methods. We show that the number of false positive reduce drastically by combining three different types of change-point detection methods.

#### 1. はじめに

地震や竜巻、集中豪雨など、突発的に発生する自然災害は予測が難しく、時として深刻な被害を与えることがある。このような自然現象の多くは、限界まで蓄積されたエネルギーが急激に解放されることによって発生する。それゆえに、突発性現象の発生前には、何らかの前兆現象 (precursory phenomena) が観測されることが多い。もし、リアルタイムで取得されたデータからこの前兆現象を検出することができたなら、突発現象の被害を未然に防ぐ、あるいは被害を最小にすることが可能になると考えられる。

ここで、時系列データにおける前兆検出の定義について述べる。一般に前兆現象とは、突発的に発生する激しい変動の前に付随して見られる、微小な変動のことを指す。図 1 に示すように、突発的な激しい現象の開始時刻を main onset、前兆現象の開始時刻を precursory onset と呼ぶことにする。すると、時系列データから前兆現象を検出することは、precursor onset から main onset までの期間を同定する問題と定義することができる。

<sup>†1</sup> 明治大学先端数理科学インスティテュート

Meiji Institute for Advanced Study of Mathematical Sciences

<sup>†2</sup> 九州大学システム情報科学研究所

Faculty of Information Science and Electrical Engineering, Kyushu University

<sup>†3</sup> 明治大学先端数理科学研究科

Graduate School of Advanced Mathematical Sciences, Meiji University

<sup>†4</sup> 統計数理研究所

The Institute of Statistical Mathematics

<sup>†5</sup> 九州大学理学研究院地球惑星科学部門

Earth and Planetary Science, Graduate School of Sciences, Kyushu University

<sup>†6</sup> 九州大学宇宙環境研究センター

Space Environment Research Center, Kyushu University

<sup>†7</sup> 宇宙航空研究開発機構宇宙科学研究所

Institute of Space and Astronautical Science, Japan Aerospace Exploration Agency

<sup>†8</sup> 東北大学惑星プラズマ大気研究センター

Planetary Plasma and Atmospheric Research Center, Tohoku University

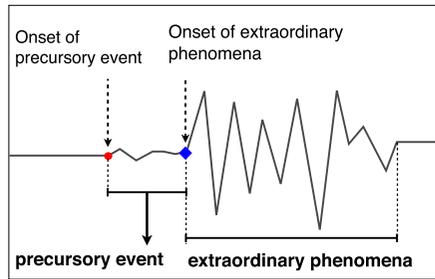


図 1 時系列データ中の前兆現象 (precursory event) の概念図。前兆現象は、precursor onset から main onset までの区間として定義できる

Fig. 1 A schematic illustration of precursory events in time series. Precursory events are defined as the interval between the precursor onset and the main onset.

次に、時系列データからの前兆検出について、変化点検出という立場から論ずる。一般に、時系列データの動的特性が急激に変化する時刻は変化点と呼ばれる。また、時系列データから変化点の時刻を決定する問題は変化点検出と呼ばれ、数多くの先行研究が存在する。代表的なものとしては、Fourier 解析や Wavelet 解析を用いたもの<sup>(17),(18),(23)</sup>、AR モデルを用いたもの<sup>(2),(7)</sup> などがある。より最近のものとしては、テキストマイニングによるもの<sup>(11),(19),(20)</sup>、クラスタリングによるもの<sup>(4)</sup>、あらかじめ決めた前兆パターンによるもの<sup>(8)</sup> などがある。前兆現象は「点」ではなく、一定の期間継続する現象である。しかしながら、前述の定義を用いるなら、時系列データからの前兆検出は precursor onset と main onset という 2 種類の変化点を検出する問題と置き換えることができる。

前述のとおり、前兆現象は突発現象に比べ微小な変動である。ゆえに、時系列データを見ても、前兆現象がどの時点から始まっているのか定義することは容易ではない。これまでの変化点検出法は、そのような微小で曖昧な変化点をとらえる問題を積極的には取り扱ってこなかった。それに対し、近年、特異スペクトル分析を応用した変化点検出法である SST (Singular Spectrum Transformation)<sup>(9)</sup> を MSST (Multivariable SST) へと改良したものが、微小で曖昧な変化をとらえることができる鋭敏な手法として提案されている<sup>(24)</sup>。MSST は従来の変化点検出法と比べてきわめて鋭敏な手法であるが、その分ノイズの影響を受けやすいという短所もある。したがって、実データを用いたオンライン前兆検出では、誤検出が頻発し実用的とはいえない。また、SST および MSST のスコアは、変化を観測した時刻を過ぎると素早く 0 レベルに戻る性質がある。そのため、変化が始まる「点」を検出するうえ

では強力な手法であるが、前兆現象の「期間」を検出することには不向きである。

我々は上記の問題を克服するため、性質の異なる複数の変化点検出法を組み合わせることで、オフラインによる効率的な前兆検出が可能なアルゴリズムを提案する。本提案手法は、初めに突発現象の大まかな時刻をあらかじめ推定し、そこから時間を遡って precursor onset と main onset の時刻を決定する、という枠組みに基づくものである。3.1 節において、今回新たに導入する変化点手法により、突発現象の大まかな開始時刻を検出する枠組みを示す。3.2 節で、MSST による precursor onset を検出する枠組みを、3.3 節で、Fukuyama<sup>(5)</sup> で提案された Bayes 推定を用いた変化点検出法により、main onset を検出する枠組みを示す。

## 2. オーロラサブストーム

本稿では、前兆検出アルゴリズムの実データへの適用例として、オーロラサブストームの前兆検出問題を取り上げる。オーロラサブストームは、夜側高緯度においてオーロラの発光強度が爆発的に増大し、その 1 時間程度擾乱が継続する現象である。サブストームは、太陽風と地球磁気圏の相互作用によって発生することが分かっているが、特に夜側磁気圏尾部におけるエネルギーの蓄積・解放過程が重要な役割を果たしているとされる。その研究は、地上における光学観測、磁場観測とともに、現在では人工衛星による磁気圏での直接観測も行われている。

図 2 (a) は、1997 年 1 月 12 日に、Polar 衛星によって光学観測された、北半球のオーロラの  $N_2$  Lyman-Birge-Hopfield bands (1,400–1,600 Å) における UVI (ultra violet imager) データである。このデータから、15:44:09UT (Universal Time) から 15:45:51UT の途中で、真夜中付近のオーロラ発光領域が急速に拡大しはじめたことが分かる。このようなオーロラ増光現象は、オーロラブレイクアップと呼ばれる。一方で、15:42:37UT から 15:42:55UT の間で、オーロラ発光強度が局所的に増強しはじめていることが見て取れる。この現象は、オーロラのイニシャルブライティングと呼ばれ、しばしばオーロラブレイクアップとは区別される<sup>(12)</sup>。イニシャルブライティングからオーロラブレイクアップに至る一連のプロセスは、オーロラサブストーム開始時に普遍的に見られる現象である。

この例のように、オーロラサブストームの始まり (オンセット) は、イニシャルブライティングとブレイクアップの 2 段階のオーロラ増光からなっていることが知られている。統計的には、オーロラブレイクアップの 1–3 分前からイニシャルブライティングが開始するとされている。つまり、イニシャルブライティングはオーロラブレイクアップの前兆現象であ

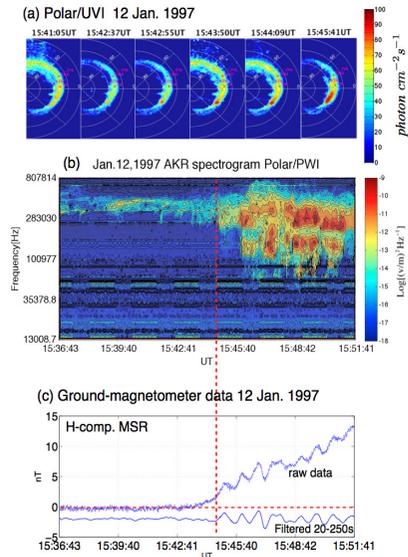


図 2 (a) 1997 年 1 月 12 日に Polar 衛星で撮影された  $N_2$  Lyman-Birge-Hopfield bands (1,400–1,600 Å) における UVI (ultra violet imager). (b) 1997 年 1 月 12 日に Polar 衛星で観測された, AKR (auroral kilometric radiation) スペクトル. (c) 環太平洋地磁気観測網 (CPMN) の MSR (母子里) で観測された, オーロラサブストーム発生前後の地上磁場の時間変化の生データと bandpass filter 処理を施した後のデータ. 赤色の垂直方向の破線は, 目視で決定した, 突発的な振動成分の開始時刻を示している. また, 赤色の水平方向の破線は, オーロラサブストーム発生前の, 磁場のベースラインを示している

Fig. 2 (a) Polar/UUVI images at  $N_2$  Lyman-Birge-Hopfield bands (1,400–1,600 Å) on 12 January 1997. (b) AKR spectrogram provided by Polar/PWI electric fields observations on 12 January 1997. (c) Northward component of ground magnetometer data obtained at KAG station. The vertical dashed line in red shows the onset time of extraordinary oscillations determined by visual inspection. The horizontal dashed line in red shows the base line of ground-magnetometer data before onset of the auroral substorm.

ると解釈することができる.

次に, 光学観測とは別の観測データから, オーロラサブストームの前兆現象について述べる. 図 2 (b) は, 同じく Polar 衛星の Plasma Wave Instrument (Polar/PWI) によって観測された, オーロラサブストーム発生時のプラズマ波動のスペクトルである. サブストーム発生時には, 夜側高緯度帯上空 2,000–16,000 km 付近で, AKR (auroral kilometric radiation) と呼ばれる 30–800 kHz 帯のプラズマ波動が観測されることが知られている.

表 1 本稿で使用した CPMN 地上磁場観測点の地理座標

Table 1 The geographic coordinates of the CPMN stations that used in this study.

Station	地理緯度	地理経度
CBI (父島)	27.15	142.30
KAG (鹿児島)	31.48	130.72

AKR は, オーロラの急激な増光のもとになるオーロラ粒子の加速域を, リモート観測するためのツールとして用いられている<sup>10),15)</sup>.

図 2 (b) から, 15:44 UT 付近から, 低周期の AKR 強度が爆発的に増強していることが分かる. 一方で, 15:39 UT 前後から, 高周期の AKR が微かながら観測されていることも見て取れる. これまでの研究から, 高周期の AKR は, オーロラのイニシャルブライティングの開始と, 低周期の AKR は, オーロラのブレイクアップと同期して始まることが分かっている<sup>13),14)</sup>. この高周期 AKR の緩やかな開始も, 低周期 AKR の爆発的な増強の前兆現象であると解釈できる.

最後に, 地上磁場データから, オーロラサブストームの前兆現象について述べる. オーロラサブストーム発生時には, 地球規模の磁場変動が観測される. 図 2 (c) は, 日本の MSR (母子里) で観測された地上磁場 H 成分 (北向き成分) の時間変化である. 地上磁場データは, 九州大学宙空環境研究センターが収集・管理する, 環太平洋地磁気観測網 (CPMN) で得られたものである<sup>26)</sup>. 地上磁場観測点の地理座標を, 表 1 に示す. 磁場データの時間分解能は 1 秒である. 図 2 (c) において, 赤色の垂直方向の破線は, 突発的な振動成分が開始時刻が開始している時刻を示している. この時刻は, 目視で大まかに推定したものである. このような突発的な磁場の振動成分は, Pi 型の地磁気脈動と呼ばれている. 特に, オーロラサブストームと連動して発生する Pi は, Pi 2 型地磁気脈動と呼ばれる<sup>22)</sup>.

本稿では, 提案アルゴリズムにより地上磁場データからオーロラサブストームの前兆現象を効率的に検出できることを示す. 大規模なオーロラサブストームが発生すると, 宇宙空間を飛翔する人工衛星にダメージを与え, しばしば深刻な通信障害を引き起こすことがある. また, 地上の送電線に過剰な電流を流し, 大規模な停電を引き起こすこともある. このようなインフラ障害を未然に防ぐために, オーロラサブストームの直前予測は重要である. たとえば, 大規模なオーロラサブストームの発生を直前に予測することができれば, 一時的に送電をストップするなどして, 地上送電線の損傷を防ぐことが可能と考えられる. さらに, オーロラサブストームの発生メカニズムについてはいまだよく分かっていない. 特に, い

つ、どこで、どのような条件下でサブストームが発達を始めるのか、その開始メカニズムについては長い論争がある。地上や衛星で観測されたデータから、現象の開始時刻を正確かつ客観的に決定することは、このサブストームの開始メカニズムを明らかにするうえで最も重要な課題とされている。

自然現象を対象にしたデータ解析では、必ずしも正解が分からないため、検出の精度を議論するのが難しい。しかし前述のとおり、オーロラサブストーム研究に関しては、光学観測、磁場観測、人工衛星による磁気圏での直接観測が行われているため、複数の観測データをつき合わせて判断することで、部分的に精度を議論することが可能である。また、一般に、人工衛星のデータはそのときの衛星の位置に激しく依存する。それに対し、地上では定常観測が可能である。さらに、現在では世界規模に展開したネットワーク観測が行われているため、様々な地方時においてオーロラサブストームのリアルタイム監視が可能である。それらの理由により、本研究では地上磁場データからのオーロラサブストームの前兆現象検出を目指す。

### 3. オフラインによる前兆検出アルゴリズム

図3に、我々の提案する前兆検出アルゴリズム全体像を示す。アルゴリズムは次の4段階からなる。(1) 新たに導入した変化点検出法であるSVTにより、突発現象のオンセットタイム  $t_0$  とオフセットタイム  $t_1$  を検出する。SVTには、事前に  $K, L, M$  および  $\tau$  の4つのパラメータを設定する必要がある。それぞれのパラメータの意味については、3.1節で言及する。(2) 現象に特化した基準により、eventのscreeningを行う。Event screeningに必要な4つのパラメータ ( $\eta_1, \eta_2, \Delta P$  および  $\Delta B$ ) については、3.4節および3.5節で言及する。(3)  $t_0$  から時刻を遡って、MSSTにより precursor onset を検出する。MSSTには、事前に  $K, L, g, m, n$  および  $j$  の6つのパラメータを設定する必要がある。さらに、探索区間を設定するために、2つのパラメータ ( $\xi_1$  および  $\xi_2$ ) を設定する必要がある。それぞれのパラメータの意味については、3.2節および3.4節で言及する。(4)  $t_0$  近傍で、文献5)によるBayes推定を用いた変化点検出法により、main onset を検出する。事前に設定すべきパラメータ  $a^*$  については、3.3節で言及する。また、探索区間を設定するために、2つのパラメータ ( $\mu_1$  および  $\mu_2$ ) を設定する必要がある。これらのパラメータについては、3.4節で言及する。(3)と(4)については、順序を入れ替えてもよい。

#### 3.1 突発現象の検出

我々の提案する前兆検出アルゴリズムの最初のステップは、オフラインによる突発現象の

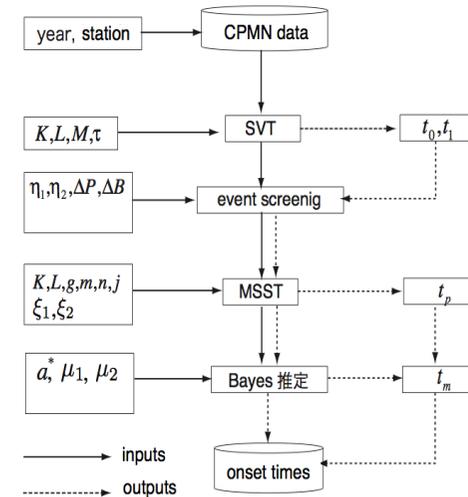


図3 オフラインによる前兆検出アルゴリズム全体像  
Fig.3 A whole picture of proposed algorithm.

検出である。本節では、そのための新たな手法を導入する。突発現象の検出は、変化点検出の特殊なケースと見なすことができる。すなわち、突発現象の開始するときの変化点（オンセットタイム）と、終了するときの変化点（オフセットタイム）を検出する問題である。問題は、いかにして突発現象とは直接関係のない変化点を避けながら、突発現象を検出するかである。なぜなら、実データには非定常なトレンド成分が重畳されていることが多く、いわば変化点は突発現象の発生の有無によらずつねに存在するからである。本研究では、特異スペクトル分析 (singular spectrum analysis, 以下, SSA と記載) を応用した変化点検出法を提案する。

#### 3.1.1 Singular Spectrum Analysis

SSAは、非定常な時系列データの解析に応用されてきた。その大まかな枠組みは、ハンケル行列を特異値分解により特異値と特異行列に分解し、特異行列を時系列の特徴として用いるというものである。特異値分解そのものはノンパラメトリックかつ数値的に安定した手法であるため、SSTは、様々な性質の時系列データに適用可能である。以下に、SSAの大まかな枠組みについて述べる。

まず、長さ  $N$  の時系列  $Y = \{y_1, y_2, \dots, y_N\}$  を考える。  $Y$  から、長さ  $K$  の部分時系列

$X_i = (y_i, \dots, y_{i+K-1})$  を  $L$  個切り出し、次式で表せるような行列を生成する。

$$\mathbf{X} = \begin{pmatrix} y_1 & y_2 & \cdots & y_K \\ y_2 & y_3 & \cdots & y_{K+1} \\ \vdots & \ddots & \vdots & \vdots \\ y_L & y_{L+1} & \cdots & y_N \end{pmatrix}. \quad (1)$$

このような形の行列を、 $L$ -軌道行列もしくはハンケル行列と呼ぶ。さらに、 $K$  および  $L$  を、それぞれ窓幅 (window width) および埋め込み次元 (embedding dimension) と呼ぶ。 $N, K, L$  の関係として、 $N = L + K - 1$  が成り立つ。

次に、この行列  $\mathbf{X}$  の特異値分解を考える。ここからは簡単のため、 $K = L$  のとき、すなわち  $\mathbf{X}$  が正方行列の場合について考える。このとき、 $\mathbf{X}\mathbf{X}^T$  は  $\mathbf{X}$  の分散共分散行列となる。今、 $\mathbf{X}\mathbf{X}^T$  の固有値を降順に並べたベクトルを  $(\lambda_1, \lambda_2, \dots, \lambda_L)$  とする。これらに対角成分を持つ対角行列を  $\mathbf{\Lambda}$  とすると、 $\mathbf{X}$  の固有値分解は  $\mathbf{X} = \mathbf{U}\mathbf{\Lambda}\mathbf{V}^T$  と表される。 $\mathbf{U}$  を左特異行列、 $\mathbf{V}$  を右特異行列と呼ぶ。 $\mathbf{U}$  の第  $i$  列ベクトルを  $U_i$ 、 $\mathbf{V}^T$  の第  $i$  行ベクトルを  $V_i^T$  とすると、 $U_i$  および  $V_i^T$  はもとの時系列を構成する直交基底と見なすことができる。このとき、 $\mathbf{\Lambda}$  の第  $(i, i)$  成分はそれぞれの直交基底のパワーに相当する。また、 $K \neq L$  のとき、 $U_i$  を経験的直交関数 (Empirical Orthogonal Function)、 $V_i^T$  を主成分 (Principal Component) と呼ぶ。このように、時系列から生成したハンケル行列の特異値分解によって、時系列の構造を抽出する枠組みを、特異スペクトル分析 (SSA) と呼ぶ。

### 3.1.2 Singular Value Transformation

前項で、SSA の大まかな概念について述べた。近年、SSA を応用した変化点検出法の開発が行われている<sup>16)</sup>。特に、Ide ら<sup>9)</sup> では、SSA を用いた変化点検出法を改良し、SST (Singular Spectrum Transformation) と名付けた。しかしながら、SST の枠組みそのままでは、突発現象の検出するうえで問題となる点がある。3.2 節で述べるが、SST では現在時刻近傍にテスト区間を、テスト区間よりも過去側に参照区間を設定し、CP-score (Change-Point Score) を算出する。これは、通常の変化点検出では、変化をとまなう時刻を検出した後には、できるだけ早く CP-score が 0 レベルに戻ることに望ましいからである。一方で、オフラインで突発現象を検出する場合、検知したい情報は、突発現象の開始時刻から終了時刻までの区間である。したがって、突発現象の検出には、突発現象が継続している期間中はずっと、CP-score も継続して立ち上がり続けることが望ましい。そこで本研究では、特異行列ではなく特異値の特徴を用いた変化点検出法 (Singular Value Transformation) を提案す

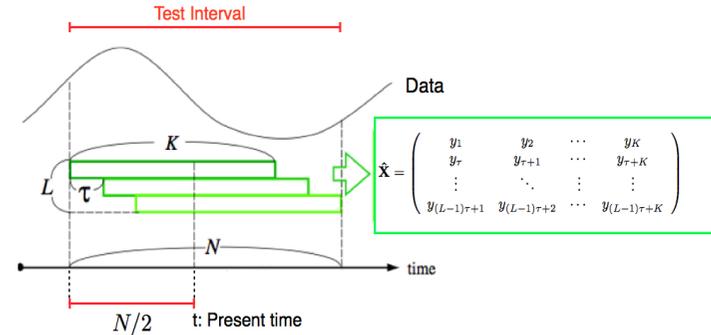


図 4 SVT の概念図。事前に定めた長さ  $N$  のテスト区間から、長さ  $K$  の部分時系列を、 $\tau$  ずつスライドさせながら  $L$  個切り出して、ハンケル行列を生成する。現在時刻  $t$  は、テスト区間の中心で定義する

Fig. 4 Conceptual scheme of SVT. The Hankel matrix  $\mathbf{X}$  consists of  $L$  subsequences whose length is  $K$ . The present time is defined as the center of the test interval.

る。以下にその詳細な枠組みを述べる。

今、任意の時系列データから、図 4 に示すように、スライド幅  $\tau$  を設定してハンケル行列を生成することを考える。部分時系列を切り出してくる長さ  $N$  の区間をテスト区間と名付ける。ここから、長さ  $K$  の部分時系列を  $L$  個切り出してくる。 $\tau$  を設定すること以外は、前項で述べた通常の SSA の手順と同じである。 $\tau$  を設定する理由は、変化を感じた後も Score がすぐに 0 レベルに戻らないようにするためと、特異値分解の回数を減らして計算コストを抑えるためである。このとき、 $N, L, K$  および  $\tau$  の関係としては、 $N = (L - 1)\tau + K$  が成り立つ。また、ハンケル行列  $\hat{\mathbf{X}}$  は

$$\hat{\mathbf{X}} = \begin{pmatrix} y_1 & y_2 & \cdots & y_K \\ y_{\tau+1} & y_{\tau+2} & \cdots & y_{\tau+K} \\ \vdots & \ddots & \vdots & \vdots \\ y_{(L-1)\tau+1} & y_{(L-1)\tau+2} & \cdots & y_{(L-1)\tau+K} \end{pmatrix} \quad (2)$$

と記述できる。

次に、SSA の場合と同様に、ハンケル行列の特異値分解を考える： $\hat{\mathbf{X}} = \hat{\mathbf{U}}\hat{\mathbf{\Lambda}}\hat{\mathbf{V}}^T$ 。ここからは前項と同様に、 $K = L$  のとき、すなわち  $\hat{\mathbf{X}}$  が正方行列の場合について考えることとする。このとき、 $\hat{\mathbf{X}}\hat{\mathbf{X}}^T$  は  $\hat{\mathbf{X}}$  の分散共分散行列となる。今、 $\hat{\mathbf{X}}\hat{\mathbf{X}}^T$  の固有値を降順に並べたベクトルを  $(\hat{\lambda}_1, \hat{\lambda}_2, \dots, \hat{\lambda}_L)$  とする。我々の提案する変化点検出法では、この固有値の特

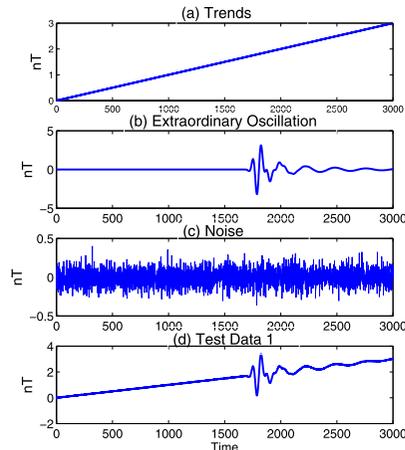


図 5 図 2(c) を模して生成した Test Data 1. (a) 傾きが 0.01 のトレンド成分. (2) Pi 2 型地磁気脈動を模して生成した突発的な振動成分. (c) 平均 0, 分散 0.1 の正規雑音. (d) トレンド成分, 振動成分およびノイズ成分を足し合わせて生成した Test Data 1

Fig. 5 Test Data 1 generated based on ground-magnetometer data shown in Fig. 2(c). (a) Trend components. (2) Extraordinary oscillations. (c) Gaussian noise. (d) Test Data 1 generated as a combination of (a), (b) and (c).

性が時々刻々どのように変化するかに着目する. ここで, 図 4 において, 現在時刻をテスト区間の中心の時刻として設定している. 現在時刻をテスト区間中のどこに設定するのが最もよいかは一概にいえませんが, 特に理由がない限り, ハンケル行列の影響が及びやすい, テスト区間の中心付近に現在時刻を設定することが妥当と思われる.

図 5(d) は, 実験のために生成した Test data 1 である. Test data 1 は, 傾きが 0.01 のトレンド成分 (図 5(a)), Pi 2 型地磁気脈動を模して生成した突発的な振動成分 (図 5(b)) および平均 0, 分散 0.1 の白色ノイズ (図 5(c)) を足し合わせることで生成した.

図 6(a) は, 図 5 に示したテストデータに対し,  $K = 100, L = 100, \tau = 50$  でハンケル行列を生成したときの,  $i = 1, \dots, 20$  までの  $\hat{\lambda}_i$  の寄与率の時間変化を示している. ここで,  $\hat{\lambda}_i$  は  $\hat{\Lambda}$  の第  $(i, i)$  成分を示す. ハンケル行列を生成する枠組みは図 4 および式 (2) に基づく. (b) は (a) の  $t = 250$  の時刻の  $\hat{\lambda}_i$  を切り出したものである. 同様に, (c) は (a) の  $t = 1,400$  の時刻の  $\hat{\lambda}_i$  を切り出したものである.  $t = 250$  においては,  $\hat{\lambda}_1$  (第 1 主成分の特異値) のみ寄与率が飛び抜けて大きいことが分かる. 一方,  $\hat{\lambda}_2, \dots, \hat{\lambda}_{20}$  の寄与率はほと

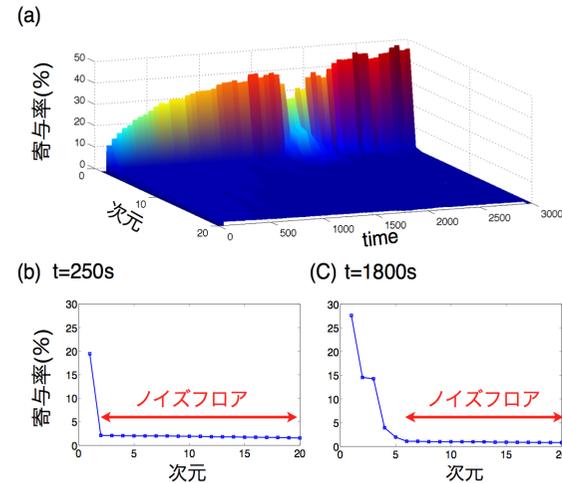


図 6 (a) 図 5(d) の Test data 1 に対し,  $K = 100, L = 100, \tau = 50$  でハンケル行列を生成したときの, 特異値の寄与率の時間変化. それぞれの時刻の特異値は,  $i = 1, \dots, 20$  をプロットしてある. (b)  $t = 250$  s における特異値. (c)  $t = 1,400$  s における特異値

Fig. 6 (a) Time variation of the contribution ratio of singular values calculated with  $K = 100, L = 100, \tau = 50$  for the Test data 1 shown in Fig. 5. (b) Singular values at  $t = 250$  s. (c) Singular value at  $t = 1,400$  s.

んど等しく, いわゆるノイズフロアを形成していることが見て取れる. これは, 特異行列の第 1 主成分がこの時刻のテストデータの主要な構造を表現する成分で, 第 2 主成分以降はノイズ成分であることを示している.

次に, 突発現象が始まっている  $t = 1,400$  の時刻について考察する. この期間のハンケル行列の特異値分解によって得られる特異値の寄与率は,  $\hat{\lambda}_1, \dots, \hat{\lambda}_5$  までは高次になるに従って緩やかに減少し,  $\hat{\lambda}_6, \dots, \hat{\lambda}_{20}$  はほぼ一定である. これは,  $i = 1, \dots, 5$  の成分が時系列の主要な構造を表現する成分であり, 第 6 成分以降がノイズ成分であることを示している. これらの結果から分かることは, 変動の少ない時刻 (突発現象が発生していない時刻) においては, 少ない主成分で時系列の構造を表現することが可能であり, 突発的な擾乱成分が含まれる期間は, 時系列の構造を表現するのにより高次の主成分まで必要になることである.

前述のように, 時系列の構造を表現するのに必要な主成分の数を調べることで, 突発現象の発生の有無を調べることができる. ここで, 時系列の構造を表現するのに必要な主成分の次元数を  $d$  とする. 前述のとおり, ノイズ成分に対応する特異値の寄与率は,  $i$  を変化させ

## 20 変化点検出を応用した時系列データからの突発現象の前兆検出アルゴリズム

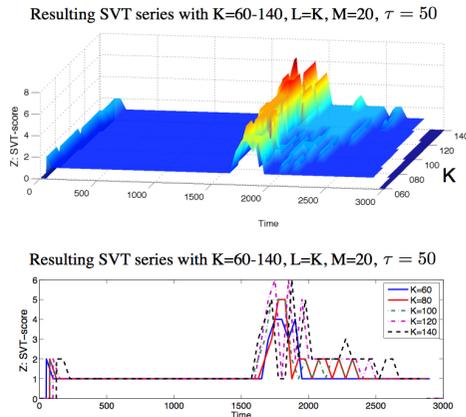


図 7 Test data 1 に  $K$  の値を変えながら SVT を適用した結果. SVT パラメータは  $K = 60-140$ ,  $L = K$ ,  $M = 20$ ,  $\tau = 50$

Fig. 7 Resulting SVT series for the Test data 1 with  $K = 60-140$ ,  $L = K$ ,  $M = 20$ ,  $\tau = 50$ .

でもその大きさがほとんど変化しない. ここでは, この性質を利用して, 時系列の主要な構造を表現するのに必要な次元数  $d$  を決定する. より具体的には,  $\hat{\lambda}_d - \hat{\lambda}_{d-2}$  が  $\hat{\lambda}_1/M$  を超えないという条件を採用する. ここで,  $M$  は 1 以上の整数である. この基準により決定された  $d$  の値を SVT-score と呼ぶ. また, もとの時系列データ  $T$  から SVT-score の系列 (SVT 系列) への変換

$$T \rightarrow T_v(K, L, M, \tau). \quad (3)$$

を, Singular Value Transformation (SVT) と呼ぶ. 図 10 は SVT により突発現象を検出する枠組みを示している. SVT-score が 1 を超える時刻を突発現象のオンセットタイム, SVT-score が再び 1 に戻る時刻を突発現象のオフセットタイムと定義する.

### 3.1.3 Simulation

適当な SVT パラメータを議論するため, いくつかのパラメータを規格化して Test Data 1 に SVT を適用した. まず,  $K$  および  $L$  の値を規格化して実験を行った結果を示す.

図 7 は, 図 5(d) の Test Data 1 に対し,  $K$  の値を変えながら SVT を適用した結果である. SVT パラメータは  $K = 60-140$ ,  $L = K$ ,  $M = 20$ ,  $\tau = 50$  とした. この実験では  $\tau = 50$  に設定されているため, SVT-score は 50 秒おきの離散的な値である. ただし, ここではテストデータと比較しやすいように, データ間のギャップは線形補間してテストデー

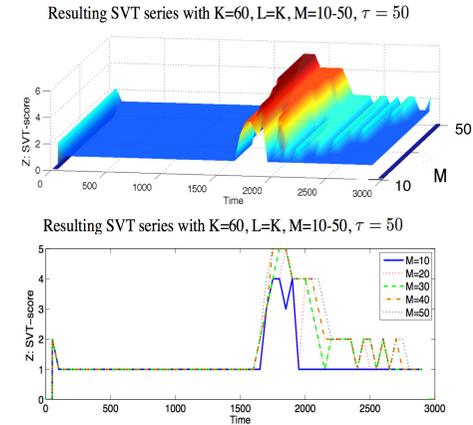


図 8 Test data 1 に,  $M$  を規格化して SVT を適用した結果. SVT パラメータは  $K = 60$ ,  $L = 60$ ,  $M = 10-50$ ,  $\tau = 50$

Fig. 8 Resulting SVT-series for the Test data 1 with  $K = 60$ ,  $L = 60$ ,  $M = 10-50$ ,  $\tau = 50$ .

タと同じデータ長にしてある. また, 図 4 に示すように, 現在時刻  $t$  は, Hankel 行列を切り出してくる区間の中心で定義する.

図 7 を見ると, テストデータ 1 の最初の期間を除いて, 何も event がない期間は SVT-score は 1 を保ち, 突発現象が継続している期間は 1 より大きな値をとっていることが分かる. この特徴は  $K$  の値に依存せず安定している. つまり,  $K=60-140$  の範囲においては  $K$  の値によらず, SVT により突発的な振動成分がうまく検出されているといえる. さらに,  $K$  が小さいほど, SVT-score が早く 1 に戻る傾向があることが分かる.

図 8 は, 図 5(d) の Test Data 1 に対し,  $M$  の値を変えながら SVT を適用した結果である. SVT パラメータは  $K = 60$ ,  $L = 60$ ,  $M = 10-50$ ,  $\tau = 50$  とした. 図 8 を見ると,  $M$  の値により検出の感度が変化していることが見て取れる. 大まかな傾向としては,  $M$  の値が大きいくほど, 突発現象を検出した際の SVT-score の値が大きく, また, 0 レベルに戻るまでの時間も長くなっている.

図 9 は, 図 5(d) の Test Data 1 に対し, 突発的な振動成分の振幅を変えながら SVT を適用した結果である. ここで, 突発的な振動成分の最大振幅を  $C$  とする. 図 9(a) は, SVT パラメータを  $K = 60$ ,  $L = 60$ ,  $M = 10$ ,  $\tau = 50$  とし,  $C$  の値を 0.1-4.0 まで変化させたときの, SVT 系列である. この実験では,  $C = 0.1$  においては SVT-score が反応しておら

21 変化点検出を応用した時系列データからの突発現象の前兆検出アルゴリズム

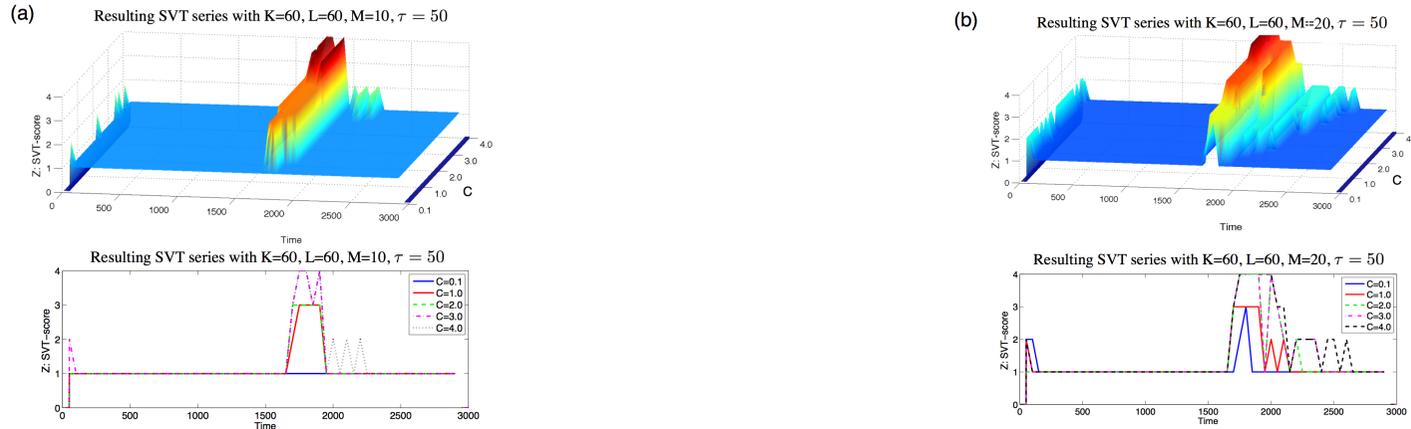


図 9 Test data 1 の突発的な振動成分の振幅を変えながら SVT を適用した結果 . (a) SVT パラメータ  $K = 60, L = 60, M = 10, \tau = 50$  で、突発的な振動成分の振幅を  $0.1\text{--}4.0\text{ nT}$  まで変化させながら SVT を適用した結果 . (b) SVT パラメータ  $K = 60, L = 60, M = 20, \tau = 50$  で、突発的な振動成分の振幅を  $0.1\text{--}4.0\text{ nT}$  まで変化させながら SVT を適用した結果

Fig. 9 (a) Resulting SVT-series with  $K = 60, L = 60, M = 10, \tau = 50$  for the different amplitude of extraordinary oscillation of Test data 1. (b) Resulting SVT-series with  $K = 60, L = 60, M = 20, \tau = 50$  for the different amplitude of extraordinary oscillation of Test data 1.

ず、検出に失敗していることが分かる．図 9(b) は、SVT パラメータを  $K = 60, L = 60, M = 20, \tau = 50$  とし、 $C$  の値を  $0.1\text{--}4.0$  まで変化させたときの、SVT 系列である．この例では、 $C = 0.1$  においても SVT-score が反応しており、検出がうまくいっていることが分かる．つまり、突発現象の最大振幅がノイズ成分と同程度の微小な変動であっても、適当な  $M$  を選択することで検出が可能になることを示している．次に、実データに SVT を適用した結果を示す．図 11(a) は、Polar/UVI data から作成した、keogram plot である．このプロットでは、横軸が時間、縦軸が磁気緯度、カラーマップが 21–03MLT (magnetic local time) で平均したオーロラの発光強度 (photon flux) になっている．ここで、赤色の垂直破線は、目視により同定したオーロラサブストームの発生時刻を示している．オーロラサブストームの発生時刻は、オーロラの発光領域が高緯度側 (北極側) に拡大し、かつ、発光強度の強まりが 30 分以上継続したケースのみ、選出した．発光領域が極側へ拡大する現象は poleward expansion と呼ばれ、オーロラサブストーム発生時のオーロラの特徴的な挙動である．図 11(b) は、CPMN の KAG において 10:00–18:00UT に観測された H 成分の地上磁場データである．参考のために、生データのほかに 20–250s の通過帯域で bandpass

filter を施したデータを掲載する．

図 12 は、図 11(b) で示した地上磁場データに SVT を適用した結果である．SVT パラメータ  $K = 60, L = 60, M = 10, \tau = 50$  で計算した．上段図は Polar/UVI から作成した keogram plot, 中段図は地上磁場データ, 下段図は SVT 系列である．データの破線は目視で決定したオーロラサブストームの開始時刻を示している．地磁気データ中のピンク色でプロットされている箇所は、そこが SVT score が 1 を超えた区間であることを示している．ここで、keogram からオーロラの発光領域が極側に拡大している時間帯を、突発現象が継続している時間と定義する．この時間帯において、SVT-score が 1 を超えていれば、検出成功とする．図 12 では、SVT-score が一度も 1 を超えておらず、すべてのオーロラサブストームの検出に失敗していることが分かる．

同様に、図 13 は、図 11(b) で示した地上磁場データに、SVT パラメータ  $K = 60, L = 60, M = 30, \tau = 50$  で SVT を適用した結果を示している．この例では、すべてのオーロラサブストームが検出されている．ただし、17:50UT 付近で SVT-score が 1 を超えている箇所があるが、対応する UVI/data が欠損しているため、評価の対象からは除外し

22 変化点検出を応用した時系列データからの突発現象の前兆検出アルゴリズム

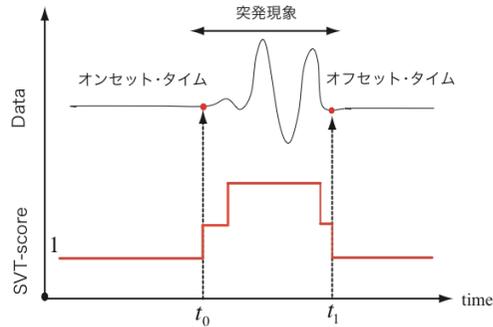


図 10 SVT による突発現象検出法の概念図. SVT-score が 1 から 2 以上になる時刻を突発現象のオンセットタイム, SVT-score が再び 1 に戻る時刻を突発現象のオフセットタイムとする  
Fig. 10 Schematic illustration of the detection of extraordinary events by SVT.

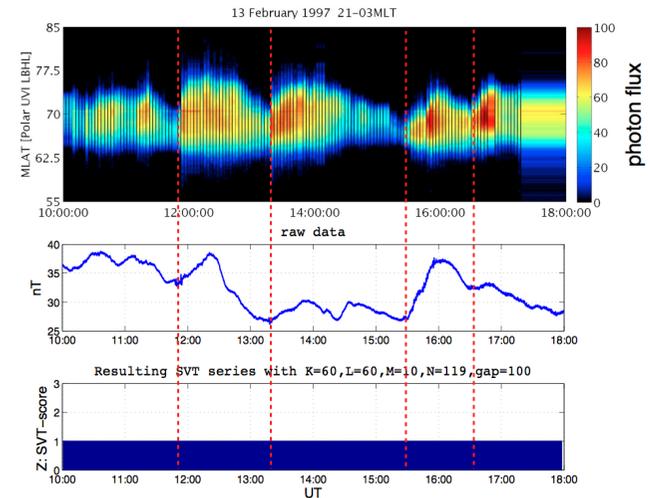


図 12 KAG で観測された地上磁場データ H 成分に, SVT を適用した結果. (上段図) Polar/UVI から作成した keogram plot. (中段図) 地上磁場データ. (下段図) SVT 系列. データの破線は目視で決定したオーロラサブストームの開始時刻. ピンク色でプロットされている区間は SVT により検出された区間を表す. SVT パラメータ  $K = 60, L = 60, M = 10, \tau = 50$  で計算  
Fig. 12 Resulting SVT-series with  $K = 60, L = 60, M = 10, \tau = 50$  for the ground-magnetometer data shown in Fig. 11. The vertical line shows the onset time of auroral substorms determined by visual inspection.

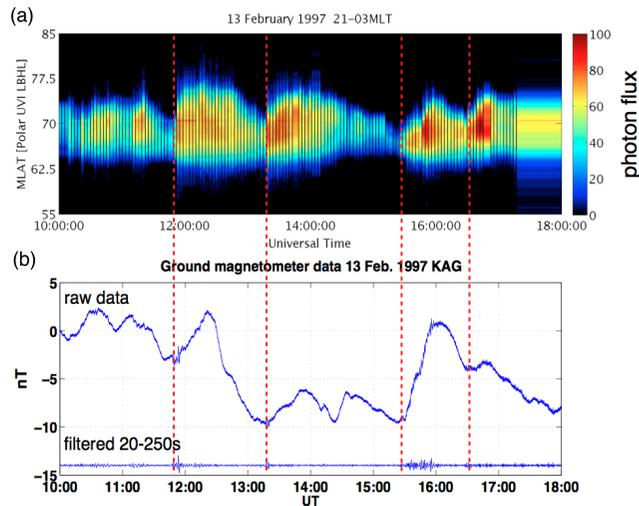


図 11 (a) Polar/UVI から作成した keogram plot. (b) 1997 年 2 月 13 日に CPMN 観測点の KAG で観測された地上磁場 H 成分の変動値と 20–250 s の通過帯域で bandpass filter 処理を施したもの  
Fig. 11 (a) Keogram plot of Polar/UVI data. (b) H-component of ground-magnetometer data obtained at KAG station and bandpass filtered data between 20–250 s.

た. これらの結果は, 適当な  $M$  を選択することによって, SVT により地上磁場データからオーロラサブストームが検出可能になることを示している.

### 3.2 SSA に基づく Precursor Onset 決定法

#### 3.2.1 Singular Spectrum Transformation

オフラインによる前兆検出の第 2 段階として, 前兆現象の開始時刻, precursor onset を精密に推定する枠組みを導入する. すでに 3.1 節で述べたように, 近年, SSA を応用した変化点検出が研究されている<sup>9),16)</sup>. 特に文献 9) では, 文献 16) の枠組みを拡張し, 対象とする時系列データを現在時刻近傍の局所相対的变化度を表す無次元量に変換する枠組みを提案した. 文献 9) では, この無次元量を CP-score と呼び, 時系列から CP-score への非線形変換を Singular Spectrum Transformation (SST) と呼んでいる.

図 14 に, SST の概念図を示す. SST では, 対象とする時系列データを図 14 のように, 現在時刻  $t$  近傍のテスト区間と, それより過去のデータからなる参照区間に分けて考える.

23 変化点検出を応用した時系列データからの突発現象の前兆検出アルゴリズム

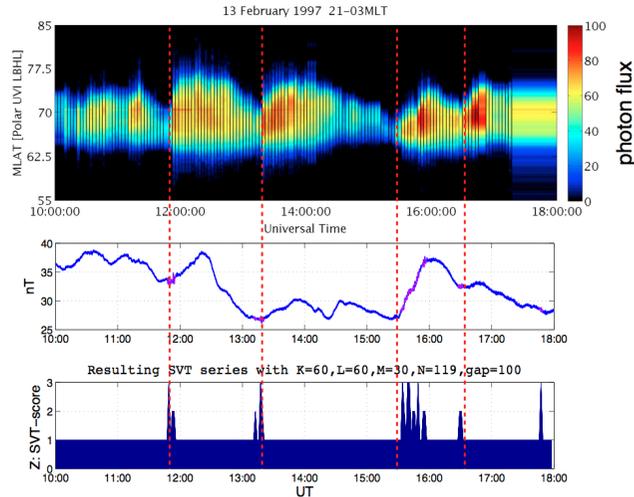


図 13 KAG で観測された地上磁場データ H 成分に、SVT を適用した結果。(上段図) Polar/UVI から作成した keogram plot。(中段図) 地上磁場データ。(下段図) SVT 系列。データの破線は目視で決定したオーロラサブストームの開始時刻。ピンク色でプロットされている区間は SVT により検出された区間を表す。SVT パラメータ  $K = 60, L = 60, M = 20, \tau = 50$  で計算

Fig. 13 Resulting SVT-series with  $K = 60, L = 60, M = 20, \tau = 50$  for the ground-magnetometer data shown in Fig. 11. The vertical line shows the onset time of auroral substorms determined by visual inspection.

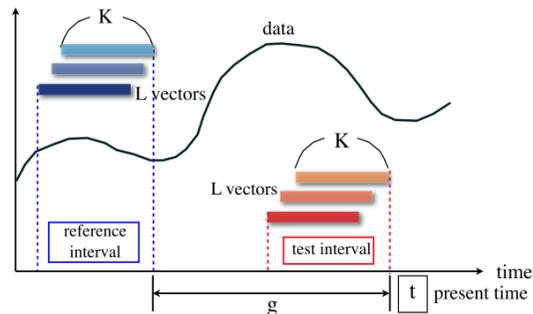


図 14 SSS の概念図。現在時刻  $t$  の過去側にテスト区間を、テスト区間よりさらに過去側に参照区間を設ける。現在時刻  $t$  はテスト区間の先端に設定する

Fig. 14 A diagram of pattern extraction by conventional SSS.

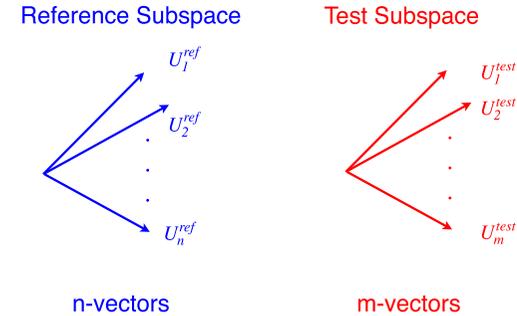


図 15 参照区間から生成した部分空間 (reference subspace) と、テスト区間から生成した部分空間 (test subspace)

Fig. 15 A diagram of the reference subspace and the test subspace.

今、テスト区間も参照区間もともに長さは  $N$  とする。3.1.1 項と同様に、 $N, L$  および  $K$  の間には、 $N = K + L - 1$  が成り立つ。 $g$  はテスト区間と参照区間の隔たりを表す。ここで、図 14 中で現在時刻  $t$  がテスト区間の先端の時刻として定義されているが、これは、可能な限り早く前兆現象を検出するためである。今、式 (1) と同様の手順で、参照区間とテスト区間それぞれからハンケル行列を生成することを考える。参照区間のデータから構成されるハンケル行列の左特異行列を  $U^{ref}$ 、テスト区間のデータから構成されるハンケル行列の左特異行列を  $U^{test}$  とする。もし、時系列データに一定期間動的な特性の変化がなければ、データはある特徴空間 (部分空間) に拘束される。SSS ではそのような観点から、2 つの部分空間  $U^{ref}$  と  $U^{test}$  どちらの距離によって、変化度 (CP-score) を定義する (図 15 参照)。

今、 $N_1 = \{1, \dots, n\}$  とすると、参照区間から生成した部分空間 (reference subspace) は、 $\mathcal{H}^{ref} = \text{span}\{U_n^{ref}\} (n \in N_1)$  と記述される。同様に、テスト区間から生成した部分空間 (test subspace) は、 $M_1 = \{1, \dots, m\}$  としたとき、 $\mathcal{H}^{test} = \text{span}\{U_m^{test}\} (m \in M_1)$  と記述される。部分空間どちらの距離尺度としては、画像パターン認識の分野で特に利用されている正準角を用いる。 $A \in R^{m \times p}, B \in R^{m \times q}$  ( $A, B$  はフル列ランクを持ち、かつ  $p \geq q \geq 1$ ) に対して、 $A, B$  の列ベクトルが生成する部分空間  $F, G$  の間の正準角  $\theta_k \in [0, \pi/2]$  ( $k = 1, \dots, q$ ) は次のように定義される<sup>3)</sup>。

$$\cos \theta_k = \max_{u \in F, v \in G} u^T v \quad (4)$$

ただし、 $u^T u = v^T v = 1$  かつ  $u^T u_i = 0, v^T v_i = 0 (i = 1, 2, \dots, k-1)$  を満たす。ここ

で, CP-score を  $Z(t)$ ,  $\mathcal{H}^{ref}$  と  $\mathcal{H}^{test}$  の間の正準角を  $\cos \theta_k$  とすると,  $Z(t)$  は

$$Z(t) \equiv 1 - \sum_{k=1}^q \cos \theta_k / q \quad (5)$$

と定義される. 定義より,  $Z$  は 0-1 の間を変動する無次元量であり, 変化が最大のとき 1 をとり, 変化が最小のとき 0 をとる. また, CP-score は局所相対的な変化度であり, その絶対値に意味があるわけではない. CP-score を計算するのに必要なパラメータは, 図 14 と図 15 に記された  $K, L, g, m, n$  の 5 つである. したがって, もとの時系列を  $T$  とすると, SST は

$$T \rightarrow T_c(K, L, g, m, n) \quad (6)$$

と記述できる.

### 3.2.2 Multivariable SST

特異値分解はノンパラメトリックで数値的にも安定した手法であるため, SST は様々な性質のデータに対応できる汎用的な変化点検出法といえる. そのため, 無限ともいえる変動パターンを示す地球科学のデータへも, 柔軟に対応できると期待される. しかしながら, 前兆現象のように初動が緩慢で変動が小さい現象のオンセットには, 従来の SST はそれほど鋭敏ではない. それに対し近年, 異なる地点で同時観測された複数の時系列データを用いた SST により, そのような緩慢な変化の開始もうまく検出できることが報告されている<sup>(24),(25)</sup>. これは, 前兆現象が複数の観測点で同期して観測されるという性質に着目したものである. 文献 24) では, 多次元の時系列データを用いた SST を, multivariable SST (以下, MSST と記載) と呼んでいる.

ここで, SST から MSST へのアルゴリズムの拡張の枠組みを示す. MSST においては, 式 (1) で示したハンケル行列は

$$\mathbf{X}_j = \begin{pmatrix} y_{j,1} & y_{j,2} & \cdots & y_{j,K} \\ y_{j,2} & y_{j,3} & \cdots & y_{j,K+1} \\ \vdots & \ddots & \vdots & \vdots \\ y_{j,L} & y_{j,L+1} & \cdots & y_{j,N} \end{pmatrix} \quad (7)$$

と記述される. ここで,  $j$  は時系列の次元数である. たとえば, 2 観測点のデータを統合して CP-score を計算する場合は,  $j = 2$  となる. 今,  $J = \{1, \dots, j\}$ ,  $N = \{1, \dots, n\}$  とすると, reference subspace は  $\mathcal{H}^{ref} = \text{span}\{U_n^{ref}\}$  ( $n \in N_j, j \in J$ ) と記述される. 同様に,

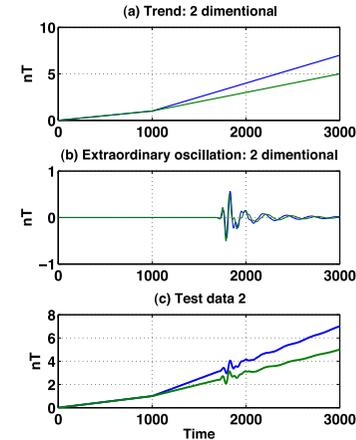


図 16 Test data 2.  $t = 1,000$  において, トレンドの傾きを変化させている  
Fig. 16 Test data 2. The slopes change at  $t = 1,000$ .

$M = \{1, \dots, m\}$  とすると, test subspace は  $\mathcal{H}^{test} = \text{span}\{U_m^{test}\}$  ( $m \in M_j, j \in J$ ) と記述される. このとき, 式 (5) で示した SST は,

$$T_j (j \in J) \rightarrow T_c(K, L, g, m, n). \quad (8)$$

と記述できる. 式 (6) および式 (7) を見れば分かるように, SST から MSST へのアルゴリズムの拡張は非常にシンプルである. しかしながら, 使用する観測点が, 解析対象とする自然現象の空間スケールと比べ “十分に近接している” 場合, このシンプルな拡張によって, 従来の SST では検出困難だった緩慢で微小な変化が精度良く検出できるようになることが報告されている<sup>(24),(25)</sup>. 今, 我々が対象としているオーロラサブストームは, 真夜中  $\pm 3$  時間程度で同様の地磁気変動を引き起こす現象である. 対して, 本研究で用いる 2 観測点 (KAG と CBI) は, 経度差で  $12^\circ$  程度 (地方時で 45 分程度) しか離れていないため, “十分に近接している” と見なしてよい.

次に, 人工データへの SST の適用例を示す. 図 16 は, 図 5 と同様に, 図 2(c) の地上磁場データを模して生成した人工データである. Test data 2 が Test data 1 と違うところは,  $t = 1,000$  においてトレンド成分の傾きが 0.01 から 0.02 および 0.01 から 0.03 に変化している点 (Test data 2 は 2 次元であることに注意) と, ノイズ成分を加えていない点である. トレンドの傾きが変化している時刻が precursor onset である. また, ノイズ成分を加えていないのは, MSST がノイズに弱い手法だからである<sup>(24)</sup>. 図 17 に示すように,

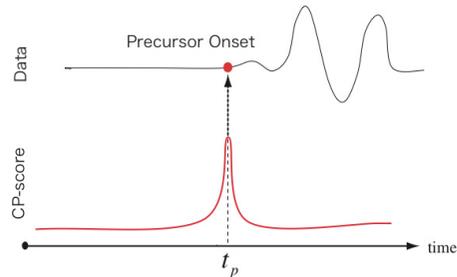


図 17 SST による precursor onset の決定法 . CP-score が最大になる時刻で precursor onset を定義する  
Fig. 17 The diagram of how to determine precursor onsets by SST.

precursor onset は CP-score が最大になる時刻で定義する . SST パラメータ  $K, L, g, m, n$  については, SST の性質上, 経験的に決定するしかない . このうち, 最も重要なパラメータである  $K$  については, 40 から 80 の間で変化させる . それ以外は,  $L = K, g = K/2, m = 1, n = 3$  とする . Precursor onset は, 各  $K$  において, あらかじめ決められた区間内で CP-score が最大となる時刻の平均として定義する .

図 18 に, Test data 2 に SST を適用した結果を示す . SST パラメータは  $K = 40-80, L = K, g = K/2, m = 1, n = 3$  である . 同様に, 図 19 に, Test data 2 に MSST を適用した結果を示す . MSST パラメータは, 図 18 の SST パラメータと同じ設定にした .

図 18 の SST 系列に関しては, 突発的な振動成分が始める時刻 ( $t = 1,200$ ) 周辺で CP-score が急激に立ち上がっていることが見て取れる . 一方で, トレンドの傾きが変化する  $t = 1,000$  では, 明確な反応は見られない . つまり, このケースのような緩やかなトレンドの変化に対し, 通常の SST はあまり鋭敏ではないことが分かる . 一方で, 図 19 の MSST 系列に関しては,  $t = 1,000$  のところで鋭く立ち上がっていることが分かる . しかも, その立ち上がり具合は  $K$  の値に依存せずほぼ一定である . すなわち, SST から MSST への拡張によって, precursor onset のような緩やかなトレンドの変化を鋭敏に検出できるようになることが分かる . ただし, 後述のように, MSST はノイズに対してあまり頑健ではない . さらに, データにノイズ成分が存在する場合,  $m$  や  $n$  の設定に検出の精度が左右されることが実験で分かっている<sup>24),25)</sup> .

### 3.2.3 SVT と SST の比較

ここで, SVT と SST という 2 つの変化点検出法の特徴を比較する . 突発現象の検出は, 通常の変化点検出とはやや目的が異なる . SST のような通常の変化点検出は, データの特

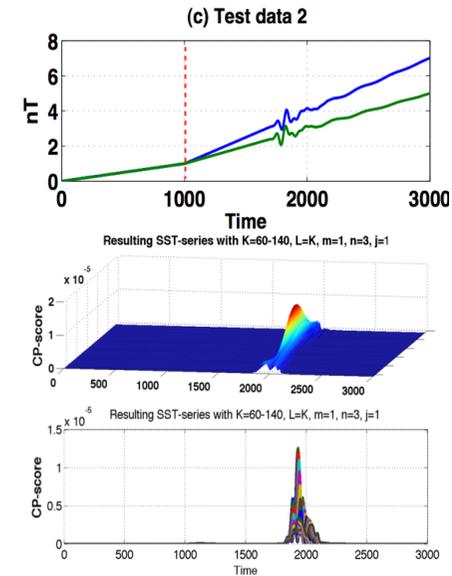


図 18 図 16 のテストデータ 2 に対して  $K = 40-80, L = K, g = K/2, m = 1$  and  $n = 3$  で計算した SST 系列 . Test data 2 (上段図) 中の赤色の垂直波線は, トレンドが変化する時刻を示している  
Fig. 18 Resulting SST series with  $K = 60-140, L = K, g = K/2, m = 1$  and  $n = 3$  for the Test data 2. The red vertical dashed line in the top panel shows the time of slope change.

性が動的に変化する 1 点を検出する問題である . そのため, 変化点の時刻でのみ CP-score が鋭く立ち上がり, その後できるだけ早く CP-score が 0 レベルに戻ることが要求される . 特に, 本研究のように緩慢な初動の開始時刻を正確にとらえたい場合には, その特徴は重要である . それに対して突発現象の検出は, 点ではなく現象が継続している期間を検出する問題である . その場合, CP-score は突発現象の継続中は 0 レベルに戻らない方が都合が良い .

図 20 は, 地上磁場データに SST を適用した結果である . 図 20 (a) の上段図は Polar/UVI から作成した keogram plot, 中段図は適用した地上磁場データ, 下段図は SST 系列である . 垂直の破線は, 目視により決定した突発現象 (Pi 2 型地磁気脈動) のオンセットを表す . 同様に, 図 20 (b) の上段図は Polar/UVI から作成した keogram plot, 中段図は適用した地上磁場データ, 下段図は MSST 系列である . SST パラメータは, とともに  $K = 60, L = K, g = K/2, m = 1, n = 3$  と設定した . 図のフォーマットは図 12 および図 13 と同様である . 中段図の地上磁場データ中に示した赤丸は, SST (あるいは MSST) によって検出され

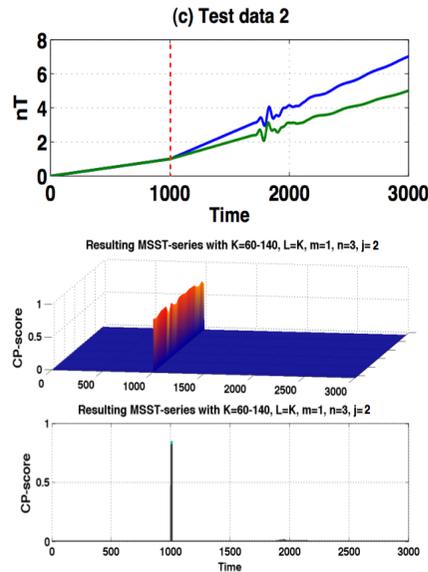


図 19 図 16 のテストデータ 2 に対して  $K = 40-80$ ,  $L = K$ ,  $g = K/2$ ,  $m = 1$  and  $n = 3$  で計算した MSST 系列. Test data 2 (上段図) 中の赤色の垂直波線は, トレンドが変化する時刻を示している  
 Fig. 19 Resulting MSST series with  $K = 60-140$ ,  $L = K$ ,  $g = K/2$ ,  $m = 1$  and  $n = 3$  for the Test data 2. The red vertical dashed line in the top panel shows the time of slope change.

た箇所を示している. 検出のあるなしは, CP-score の極大値が, あらかじめ設定した閾値を超えたかどうかで判断する. ここでは, 閾値は解析した区間における CP-score の最大値の  $1/2$  とした (たとえば, 解析区間内の CP-score の最大値が  $0.8$  の場合は, CP-score が  $0.4$  を超えたときに検出ありと判断する).

図 20 (a) を見ると, 目視して決定したオーロラサブストームの開始時刻のうち, 3 番目までのイベントは検出できていることが分かる. しかし, 4 番目のイベントは検出に失敗している. さらに, CP-score が再び  $0$  レベルに戻るタイミング (SVT に関しては  $1$  に戻るタイミング) に関しては, SVT と SST で明らかに異なることも見て取れる. SVT-score は現象が継続している間一定の値を維持しているのに対し, SST の CP-score は現象が開始する一瞬のみ鋭く反応している. すなわち, SST によって検出できるのは主に現象のオンセットタイムであり, オフセットタイムの検出にはあまり適していないといえる. 一方で, 図 20 (b) の MSST 系列を見てみると, 目視で決定した突発現象 (Pi 2 型地磁気脈動) の発

生した時刻以外でも CP-score が頻繁に閾値を超えている. 前項で示したとおり, MSST は従来の SST よりも緩慢なトレンド変化に対して鋭敏な手法であるが, その分誤検出も多くなることが分かる.

また, CP-score は  $0$  から  $1$  の間で連続的に変動する値であるのに対し, SVT-score は自然数しかとらない. この性質も, 2 つの手法のそれぞれの目的に合致している. SST を用いたオンセットタイム決定法では, CP-score が最大になる時刻でオンセットを定義する. そのため, CP-score は連続的に変動する量であった方が, オンセットタイムを厳密に決定するのに都合が良い. それに対して SVT は, SVT-score が閾値を超えるところで event ありと判断する. Score が連続的に変化する場合, 閾値の設定方法が問題になる. しかし SVT は score が離散的であるため, 閾値の設定が比較的簡単になる.

さらに, SST では参照区間とテスト区間から特徴空間を生成するのに対し, SVT は現在時刻近傍のみから部分空間を生成する. したがって, SVT の特異値分解の回数は SST の  $1/2$  で済み, 計算コストを抑えることができる. 表 2 に SVT, SST, MSST のパラメータ数と計算コストをまとめる (MSST のパラメータ数には  $j$  も含めている). 表 2 から, SVT では SST および MSST よりパラメータが少なく, かつ, 計算時間が大幅に短縮されていることが分かる. 以上のことをまとめると, SVT は突発現象の大まかなオンセットタイムとオフセットタイムを効率良く検出するのに適した手法であり, MSST はノイズに対する頑健性は低いものの, 緩慢なトレンド変化を鋭敏に検出できる変化点検出法であるといえる. オフラインによる前兆検出では, これら 2 つの手法を相補的に用いることで, 鋭敏かつノイズに robust な検出が可能となる.

### 3.3 Main Onset 決定法

オフラインによる前兆検出における第 3 段階として, 突発現象の精密なオンセットタイム (main onset) を決定する手法を紹介する. 3.1 節において, 突発現象の大まかなオンセットタイム  $t_0$  とオフセットタイム  $t_1$  をすでに推定している. 本節では, その大まかなオンセットタイム  $t_0$  の前後で, より精密に突発現象のオンセットタイムを推定する枠組みについて述べる. 本研究では, Fukuyama ら<sup>5)</sup> で紹介された, データの差分変換と Bayes 推定を用いた手法を採用する.

Fukuyama ら<sup>5)</sup> の提案手法の大まかな手続きは以下のとおりである. まず, データに差分変換を施し, 一階のトレンドモデルをあてはめることで平滑化する. 一階のトレンドモデルは  $t_n = 2t_{n-1} - t_{n-2} + \nu_n^t$ ,  $\nu_n^t \sim N(0, \tau_t^2)$  で表される. 差分変換の目的は非正常なトレンド成分を除去するため, 平滑化の目的は高周波ノイズの除去である.  $\nu_n^t$  は, 状態空間モ

27 変化点検出を応用した時系列データからの突発現象の前兆検出アルゴリズム

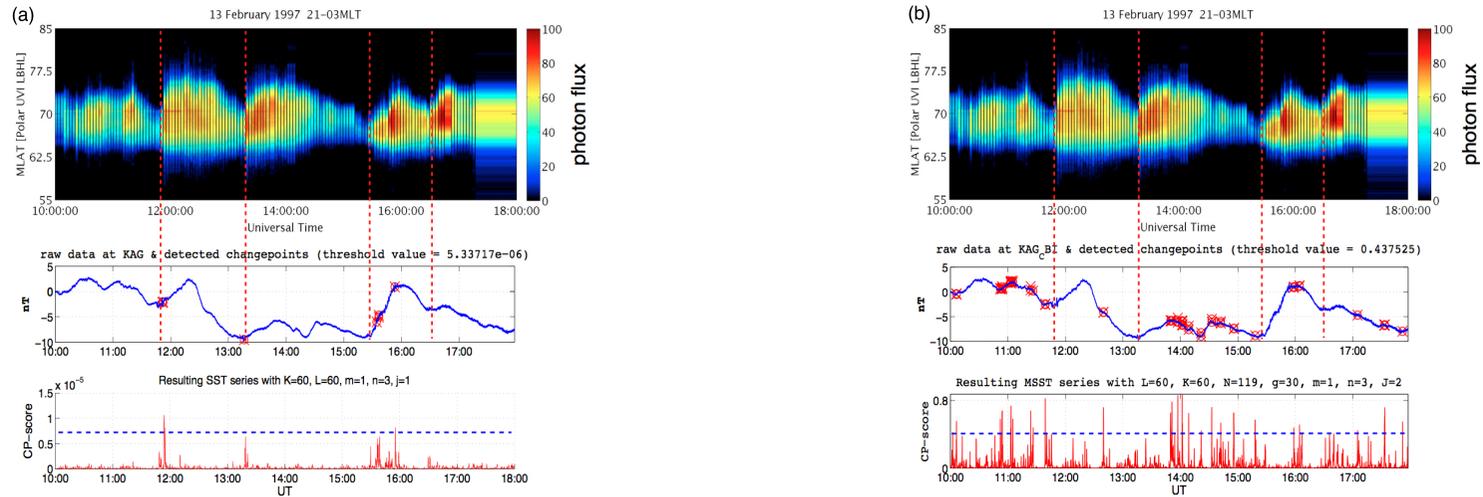


図 20 (a) 地上磁場データに  $K = 60, L = K, g = K/2, m = 1$  and  $n = 3$  で SST を適用した結果 . (b) 地上磁場データに  $K = 60, L = K, g = K/2, m = 1$  and  $n = 3$  で MSST を適用した結果  
 Fig. 20 (a) Resulting SST series with  $K = 60, L = K, g = K/2, m = 1$  and  $n = 3$  for the ground-magnetometer data. (b) Resulting MSST series with  $K = 60, L = K, g = K/2, m = 1$  and  $n = 3$  for the ground-magnetometer data.

表 2 SVT, SST および MSST のパフォーマンス比較  
 Table 2 Performance comparison between SVT, SST and MSST.

A	SVD の回数	計算時間 (秒)	パラメータ数
SVT	$N/\tau$	4.029	4
SST	$2N$	704.62	5
MSST	$2jN$	1,557.47	6

デルにおいてシステムノイズと呼ばれ、ここでは平均 0 分散  $N$  のガウス分布に従うとする。システムノイズの分散は、AIC (赤池情報量規準) を最小にすることにより決定される。次に、差分変換と平滑化処理したデータ  $Y_{m:m+W} = \{y_m, y_{m+1}, \dots, y_{m+W}\}$  に、正の傾きを持つ直線をあてはめる。望ましい直線の傾きを正に限定するのは、初期の Pi 2 研究において、“pt (=Pi 2) starts with  $dH/dt > 0$  in the middle or low latitude”<sup>21)</sup> という記述があるためである。これは、中、低緯度の Pi 2 はその微分値が正の変動をとる点から始まるという特徴を述べたものである。本研究で使用している観測点 (KAG および CBI) も、磁

気的低緯度に位置しているため、その初動は正の方向にふれると仮定してよい。傾きが最も望ましい値をとり、かつデータ誤差が最小になる直線の始点をオンセットタイムとする。

望ましい直線の傾き値の客観的な評価には、ABIC を用いる。今、あてはめる直線の傾きを  $a$  としたとき、始点以後のデータ  $Y_{m:m+W}$  と直線との誤差は  $\sum_{i=m}^{m+W} (y_i - a(i-m))^2$  で表される。また、過去のデータから経験的に求めた望ましい傾きを  $a^*$  とおくと、 $(a^* - a)^2$  が最小になるとき傾き  $a$  は最適な値をとる。直線の傾き具合とデータとの誤差における兼ね合いを左右するパラメータを  $\alpha$  としたとき、 $\sum_{i=m}^{m+W} (y_i - a(i-m))^2$  を最小化することで、オンセットタイムを推定できる。この問題を Bayes 的に解釈すると、事前分布、データ分布はそれぞれ次式で表される<sup>1),6)</sup>。

$$g(a|\alpha) = \frac{1}{(2\pi\beta^2)^{\frac{1}{2}}} \exp\left\{-\frac{(a^* - a)^2}{2\beta^2}\right\}, \quad \beta^2 = \frac{\sigma^2}{\alpha^2}$$

$$f(Y_{m:m+W}|\alpha) = \prod_{i=m}^{m+W} \frac{1}{(2\pi\sigma^2)^{\frac{W+1}{2}}} \exp\left\{-\frac{(y_i - a(i-m))^2}{2\sigma^2}\right\}$$

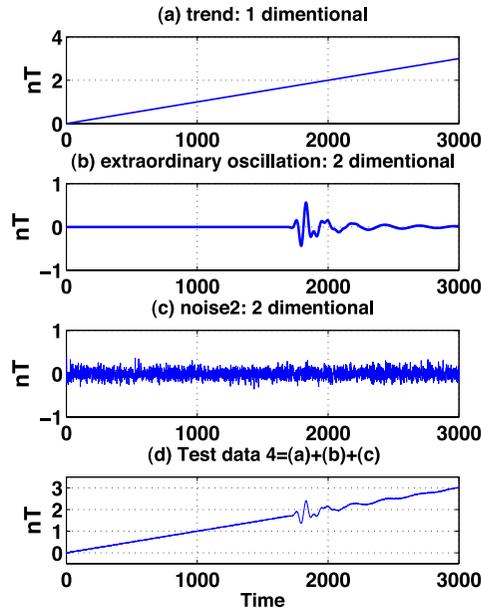


図 21 Test data 3. (a) 傾き 0.01 のトレンド成分. (b) 最大振幅 1 の突発的な振動成分. (c) 平均 0, 分散 0.1 の正規雑音. (d) (a), (b) および (c) を足し合わせて生成した Test data 3  
 Fig. 21 Test data 3 generated as a combination of the trend component (a), extraordinary oscillations (b) and gaussian noise (c). (d) Test data 3 generated as a linear combination of (a), (b) and (c).

この 2 式から, 周辺尤度

$$L(Y_{m:m+W}|a) = \int_{-\infty}^{+\infty} f(Y_{m:m+W})g(a|\alpha)da \quad (9)$$

が求まる. 式 (9) の対数をとって  $\sigma^2$  について偏微分することにより最適な  $\sigma^2$  (これを  $\sigma^{2*}$  とする) が求まり, 周辺尤度  $L$  をパラメータ  $\alpha$  のみの関数にすることができる. よって  $ABIC_m = -2 \log L(Y_{m:m+W}|\alpha, \sigma^{2*})$  を最小化とする  $\alpha$  がその始点における最適な  $\alpha$  である.

次に, 人工的に生成したテストデータに文献 5) の手法を適用した結果を示す. 図 21 に, 人工的に生成した Test data 3 を示す. 図 21 (a) は, 傾き 0.01 のトレンド成分, 図 21 (b) は最大振幅を 1 に規格化した突発的な振動成分, (c) は平均 0, 分散 0.1 の正規雑音である.

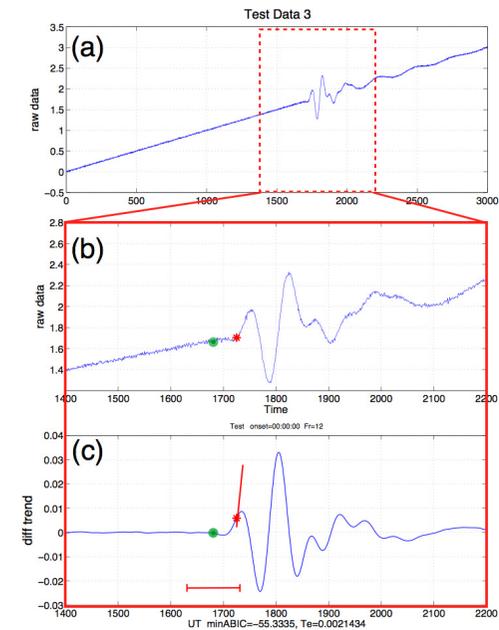


図 22 Test data 3 に, Fukuyama ら<sup>5)</sup> の提案による Bayes 推定を利用したオンセット決定法を適用した結果.  
 (a) 図 21 に示された Test data 3. 赤い星印は本手法により決定した main onset の時刻 ( $t_m$ ), 緑の星印は事前に SVT で求めた大まかなオンセットタイム ( $t_0$ ) を示している. (b) データ中の赤い星印は, 文献 5) の手法により推定されたオンセットタイムを示している. また, データ中の緑の星印は, SVT により前もって推定された, 突発的な振動成分の大まかな開始時刻 ( $t_0$ ) である. (c) (a) のデータに差分変換と平滑化処理を施したデータを, (b) と同じ区間でプロットしたもの  
 Fig. 22 Estimated main onset by the method proposed by Fukuyama et al.<sup>5)</sup>.

図 21 (d) は, (a), (b) および (c) を足し合わせて生成した Test data 3 である.

図 22 (a) は, テストデータの生データを示している. 図 22 (b) は  $t = 1,400 - 2,200$  s まで (赤の実線で囲んでいる区間) を拡大したものである. データ中の赤い星印は, 文献 5) の手法により推定されたオンセットタイムを示している. また, データ中の緑の星印は SVT により前もって推定した, 突発的な振動成分の大まかな開始時刻 ( $t_0$ ) を示している. なお, ここでは, 過去のデータから決定すべき望ましい直線の傾き  $a^*$  は 0.01 とした. 図 22 (c) は, 図 22 (a) の Test data 3 に差分変換と平滑化処理を施したものを, 図 22 (b) と同じ区間でプロットしたものである. データ中の赤い星印は, 推定されたオンセットタイムを, デー



地磁気脈動が観測される例が知られている．このようなケースは，シュードブレイクアップと呼ばれる．SVT によって選出された event の中には，このシュードブレイクアップにもなるものも含まれている可能性がある．そのような event を除外するために， $t_0$  から  $t_1$  までの間の区間の変動の大きさが  $\Delta B$  を超える event のみを，前兆検出の候補とした．

#### 4. 適用結果

図 24 に，本アルゴリズムによって検出された前兆現象の例を示す．図 24 (a) は，1997 年 2 月 13 日の Polar/UVI データから作成した keogram plot，図 24 (b) は，1997 年 2 月 13 日の 10:00–18:00UT に CPMN の KAG で観測された地上磁場データ H 成分を示している（図 11 と同じ）．赤色の垂直波線は，目視で決定したオーロラサブストームの開始時刻を示している．図 24 (c) に， $\Delta P < 1.0$  および  $\Delta B > 0.6$  という条件下で event screening を行ったときの，前兆現象検出区間（P-score が 1 となっている区間）を示す．前述のとおり，前兆現象は precursor onset と main onset で挟まれた区間で定義される．ここで，前兆現象が検出された区間を示すために，P-score を導入する．P-score は，precursor onset と main onset で挟まれた区間でのみ 1 をとり，それ以外の区間では 0 をとるものとする．図 24 (d) は， $\Delta P < 1.0$  および  $\Delta B > 1.0$  という条件下で event screening を行ったときの，前兆現象検出区間（P-score が 1 となっている区間）である．図 13 と図 24 を比較すると，図 24 (c)，(d) 双方において 2 番目と 4 番目の event（赤の破線で示したものが），event screening の対象となったことが分かる．また，図 20 (b) と図 24 を比べると，本アルゴリズムを用いることで，MSST 単体よりも誤検出が大幅に減少していることが分かる．

図 24 (c) では，1 番目と 3 番目のオーロラサブストームの前に前兆現象を検出していることが分かる．同様に，図 24 (d) では，3 番目のオーロラサブストームの前に前兆現象を検出していることが分かる．(c) と (d) 双方において，3 番目のオーロラサブストームの 10 分程度後に，別の前兆現象が検出されている．これは，オーロラサブストームはしばしば短い時間に連続して発生するためであると考えられる．

#### 5. 結 論

本稿では，オフラインによる前兆検出アルゴリズムを提案した．我々の提案手法では，SVT による突発現象の検出，検出した突発現象の screening，MSST による precursor onset の検出，Bayes 推定に基づく main onset 検出という 4 つステップからなる．

Bayes 推定に基づく main onset 検出法<sup>5)</sup>により，突発現象の開始時刻を ABIC を用い

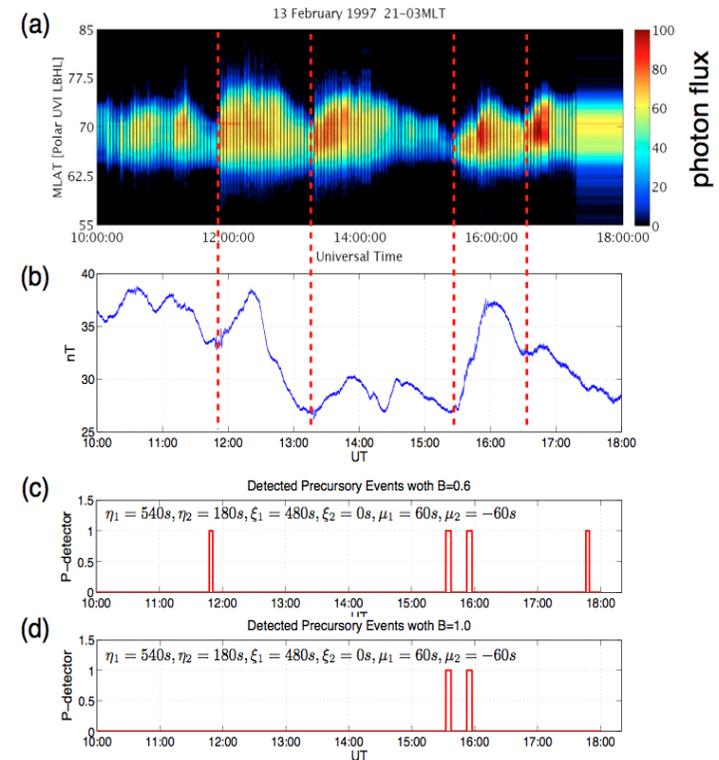


図 24 本アルゴリズムによって検出されたオーロラサブストームの前兆現象．(a) 1997 年 2 月 13 日の Polar/UVI データから作成した keogram plot．(b) 1997 年 2 月 13 日の 10:00–18:00UT に CPMN の KAG で観測された地上磁場データ H 成分．(c)  $\Delta P < 1.0$  および  $\Delta B = 0.6$  で event screening を行ったときの，前兆現象検出区間（P-score が 1 となっている区間）．(d)  $\Delta P < 1.0$  および  $\Delta B = 1.0$  で event screening を行ったときの，前兆現象検出区間（P-score が 1 となっている区間）．赤色の垂直波線は，目視で決定したオーロラサブストームの開始時刻

Fig. 24 Precursory events detected by proposed algorithm.

て客観的に推定することができるようになった．しかし，この手法を用いるには，突発現象の開始付近のデータを，手動で与えてやる必要があった．本アルゴリズムでは，事前に SVT を適用することで突発現象の大まかな開始時刻  $t_0$  を推定し，手動による操作なしに Fukuyama ら<sup>5)</sup>の手法を適用できるようになった．また，Tokunaga ら<sup>24),25)</sup>では，Ide ら<sup>9)</sup>が提案した SST を MSST に拡張することで，従来 SST および Fukuyama ら<sup>5)</sup>の提案手

法では検出困難だった, 前兆現象の微小な変化をとらえることができるようになった. しかし, MSST 単体では誤検出が多く, 自然科学のデータに適用することが難しい. 本アルゴリズムにおいては, 事前に SVT により突発現象の大まかな開始時刻  $t_0$  を推定し, さらに前兆現象の検出が事実上困難な event を事前に screening することにより, 誤検出の問題に対応できるようにした. このように, タイプの異なる変化点検出法を段階的に適用していくことで, 非定常かつノイズを含んだ自然科学のデータから, 微小で緩慢な前兆現象を検出することができるようになった.

人工的に生成したデータを解析する場合とは異なり, 自然科学におけるデータ解析では, あらかじめ正解が分かっているわけではない. 本稿では, SSA を応用した突発現象検出法や precursor onset 決定法を提案したが, それは現時点で最も適切と思われる決定法を採用したにすぎない. 今後, オーロラサブストームに関する知見が太陽地球系科学の分野において蓄積されてゆくとつれて, より適切なオンセットの定義方法が見つかる可能性もある. そのときは, 突発現象の検出法もオンセットタイム決定法も, 新たな知見を盛り込みつつ改良を加えていくことが重要である.

予報研究という観点では, 可能な限り早い段階で前兆現象を検出できることが, 突発性現象による被害を食い止めるために重要である. 一方で, 自然現象の基礎研究という観点では, 可能な限り正確に前兆の開始時刻を推定することが重要である. なぜなら, 観測点間の現象の開始時刻の時間差は, その自然現象の時空間的な発展の特性を反映しているからである. 実際, 本研究で適用対象としたオーロラサブストームについても, 地上と磁気圏での現象の開始する順序を明らかにすることが, その発生機構を解き明かすうえでの keypoint になるとされている. 地球科学の分野で用いられてきた Fourier 解析や Wavelet 解析による変化点検出法は, 基本的に直交基底に分離した信号成分のパワーが, ある閾値を超えたところでオンセットを定義するという枠組みによるものだった<sup>17),18),23)</sup>. このようなアプローチは, 閾値の設定そのものがオンセットの定義になってしまうため, 解析者の主観が入り込みやすい. また, 当然のことながら, 緩慢な初動をとらえることに適していない. 一方で, 本稿で precursor onset 決定法として採用した MSST も, Bayes 推定による main onset 決定法も, 信号のパワーに閾値を設けるのではなく, 事前に決められた区間内において変化が最大になる時刻をオンセットとして検出する手法である. 我々のアプローチは, 直交基底に分離した信号のパワーに基づく従来のオンセットタイム決定法より, より精密かつ客観的な議論が可能である. 本アルゴリズムによりオフラインで収集した前兆現象のデータベースは, オーロラサブストームの基礎研究にも今後役立てていく予定である.

突発現象の発生を予測するためには, オンラインで前兆検出を可能にする必要がある. しかし, 前兆現象の発生機構が解明されていないこともあり, オンライン前兆検出アルゴリズムの構築には至っていない. 現状では, オフラインによる前兆現象の検出と収集が, 目下の課題である. 将来的には, 本アルゴリズムにより蓄積された前兆現象を学習データとして用いることで, オンラインでの前兆検出が可能になると期待している.

謝辞 本研究では, アイオワ大学の Prof. J. Dowell に Polar/PWI データを提供していただいた. また, ジョンホプキンス大学の Dr. C. Meng と Dr. K. Liou に Polar/UVI データを提供していただいた. さらに, 地上磁場データは, 九州大学宇宙環境研究センターの環太平洋地磁気観測ネットワークプロジェクト (CPMN project, PI: 湯元清文教授) によって取得されたものを使用させてもらった. CPMN プロジェクトは, 文部科学省研究補助金 (05041060, 0841105, 10041122, 12373003) の助成を受けたものである. また, 本研究の一部は特別研究奨励費 (2005443) および挑戦的萌芽研究 (21650031) の助成を受けて行われた. 最後に, 本稿に対して貴重なコメントをくださった, 担当委員と査読者の方々に深謝する.

## 参 考 文 献

- 1) Akaike, H.: Likelihood and the Bayes procedure (with discussion), *Bayesian Statistics*, pp.143–165 (1980).
- 2) Bello, G.D., Lapenna, V., Macchiato, M., Satriano, C. and Serio, C.: Parametric time series analysis of geoelectrical signals: An application to earthquake forecasting in Southern Italy, *Annali di Geofisica*, Vol.XXXIX, No.1 (1996).
- 3) Björck, A. and Golub, H.G.: Numerical Methods for Computing Angles Between Linear Subspaces, *Mathematics of Computation*, Vol.27, No.123, pp.579–594 (1973).
- 4) Fukuda, K., Koganeyama, M., Shouno, H., Nagao, T. and Kazuki, J.: Detecting Seismic Electric Signals by LVQ Based Clustering, *International Conference on Parallel and Distributed Processing Techniques and Applications*, pp.1305–1311 (2001).
- 5) Fukuyama, K., Higuchi, T., Uozumi, T., Kawano, H. and Yumoto, K.: 初動が緩慢な波動現象開始時点の精密同定: Pi 2 型地磁気脈動オンセットタイムの決定法, 電子情報通信学会論文誌, Vol.J87-A, No.12, pp.1502–1510 (2004).
- 6) Higuchi, T., Kita, K. and Ogawa, T.: Bayesian statistical inference to remove periodic noise in the optical observation aboard a spacecraft, *Appl., Opt.*, Vol.27, pp.4514–4519 (1988).
- 7) Higuchi, T., Ohtani, S.-I., Uozumi, T. and Yumoto, K.: Pi2 onset determination

- with information criterion, *J. Geophys. Res.*, Vol.107, No.A4, p.1107 (2002).
- 8) Huang, H.-M., Fan, H.-S., Bian, Y.-J. and Zou, L.-Y.: Investigation into the automatic recognition of time series precursor of earthquakes, *Acta Seismologica Sinica*, Vol.11, No.5, pp.605–614 (1998).
  - 9) Ide, T. and Inoue, K.: Knowledge Discovery from Heterogeneous Dynamic Systems using Change-Point Correlations, *Proc. 2005 SIAM International Conference on Data Mining*, pp.571–576 (2005).
  - 10) Kaiser, M.L. and Alexander, J.K.: Relationship between auroral substorms and the occurrence of terrestrial kilometric radiation, *J. Geophys. Res.*, Vol.82, pp.5238–5286 (1977).
  - 11) Karamanos, K., Peratzakis, A., Kaporis, P., Nikolopoulos, S., Kopanas, J. and Eftaxias, K.: Extracting preseismic electromagnetic signatures in terms of symbolic dynamics, *Nonlinear Processes in Geophysics*, Vol.12, pp.835–848 (2005).
  - 12) Morioka, A., Miyoshi, Y., Miyashita, Y., Kasaba, Y., Misawa, H., Tsuchiya, F., Kataoka, R., Kadokura, A., Mukai, T., Yumoto, K., Menietti, D.J., Parks, G., Liou, K., Honary, F. and Donovan, E.: Two-step evolution of auroral acceleration at substorm onset, *J. Geophys. Res.*, Vol.115, A11213, DOI:10.1029/2010JA01536/ (2010).
  - 13) Morioka, A., Miyoshi, Y., Tsuchiya, F., Misawa, H., Sakanoi, T., Anderson, K.Y.R.R., Menietti, J.D. and Donovan, E.F.: Dual structure of auroral acceleration regions at substorm onsets as derived from AKR spectra, *J. Geophys. Res.*, Vol.112, No.A06245 (2007).
  - 14) Morioka, A., Miyoshi, Y., Tsuchiya, F., Misawa, H., Yumoto, K., Parks, G.K., Anderson, R.R., Menietti, J.D., Donovan, E.F., Honary, F. and Spanswick, E.: AKR breakup and auroral particle acceleration at substorm onset, *J. Geophys. Res.*, Vol.113 (2008).
  - 15) Morioka, A., Oya, H. and Miyatake, S.: Terrestrial kilometric radiation observed by satellite Jikiken (Exos-B), *J. Geomag. Geoelectr.*, Vol.33, pp.37–62 (1981).
  - 16) Moskvina, V. and Zhigljavsky, A.: An Algorithm Based on Singular Spectrum Analysis for Change-Point Detection, *Communications in Statistics — Simulation and Computation*, Vol.32, pp.319–352 (2003).
  - 17) Muphy, R.K., Rae, I.J., Mann, I.R., Milling, D.K., Watt, C.E., Ozeke, L., Frey, H.U., Angelopoulos, V. and Russel, C.T.: Wavelet-based ULF wave diagnosis of substorm expansion phase onset, *J. Geophys. Res.*, Vol.114, No.A00C16 (2009).
  - 18) Nose, M., Iyemori, T., Takeda, M., Kamei, T., Milling, D.K., Orr, D., Singer, H.J., Worthington, E.W. and Sumitomo, N.: Automated detection of Pi 2 pulsations using wavelet analysis: 1. Method and an application for substorm monitoring, *Earth, Planetary and Space Sciences*, Vol.50, pp.773–783 (1998).
  - 19) Ohsawa, Y.: KeyGraph as Risk Explorer in Earthquake-Sequence, *Journal of Contingencies and Crisis Management*, Vol.10, pp.119–128 (2002).
  - 20) Patankar, R.P., Rajagopalan, V. and Ray, A.: Failure precursor detection in complex electrical systems using symbolic dynamics, *International Journal of Signal and Imaging Systems Engineering*, Vol.1, No.1, pp.68–77 (2008).
  - 21) Saito, T.: Oscillation of geomagnetic field with the progress of pt-type pulsation, *Sci. Rep. Tohoku Univ.*, Vol.13, pp.53–61 (1961).
  - 22) Saito, T.: Geomagnetic pulsations, *Space Science Review*, Vol.10, pp.319–412 (1969).
  - 23) Takahashi, K., Ohtani, S. and Anderson, B.J.: Statistical analysis of Pi 2 pulsations observed by the AMPTE CCE spacecraft in the inner magnetosphere, *J. Geophys. Res.*, Vol.100, pp.21929–21941 (1995).
  - 24) Tokunaga, T., Ikeda, D., Nakamura, K., Higuchi, T., Yoshikawa, A., Uozumi, T., Fujimoto, A., Morioka, A. and Yumoto, K.: Detecting Precursory Events in Time Series Data by an Extension of Singular Spectrum Transformation, *Proc. 10th WSEAS International Conference on Applied Computer Science*, pp.366–374 (2010).
  - 25) Tokunaga, T., Ikeda, D., Nakamura, K., Higuchi, T., Yoshikawa, A., Uozumi, T., Fujimoto, A., Morioka, A. and Yumoto, K.: Onset Time Determination of Precursory Events in Time Series Data by an Extension of Singular Spectrum Transformation, *International Journal of Circuits, Systems and Signal Processing*, Vol.5, pp.46–60 (2010).
  - 26) Yumoto, K. and the CPMN Group: Characteristics of Pi 2 magnetic pulsations observed at the CPMN stations: A review of the STEP results, *Earth Planets Space*, Vol.53, pp.981–992 (2001).

(平成 22 年 11 月 18 日受付)

(平成 23 年 2 月 7 日再受付)

(平成 23 年 3 月 7 日採録)



徳永 旭将

2006年九州大学理学部地球惑星科学科卒業, 2008年同大学大学院理学府地球惑星科学専攻修士課程修了, 同年日本学術振興会特別研究員(DC1), 2011年九州大学大学院理学府地球惑星科学専攻博士後期課程修了, 2011年より明治大学研究・知財戦略機構先端数理科学インスティテュート研究推進員(PD), 現在に至る。オーロラサブストームの発生機構の解明および前兆検出法の開発, 地球磁気圏の諸現象の時系列解析・モデリングに関する研究に従事。地球電磁気・地球惑星圏学会, American Geophysical Union に所属。



池田 大輔(正会員)

1994年九州大学理学部物理学科卒業, 1996年同大学大学院総合理工学研究科情報システム学専攻修士課程修了, 1997年同大学大学院システム情報科学研究科情報理学専攻博士後期課程退学, 同大学助手, 講師を経て2006年より九州大学大学院システム情報科学研究院准教授, 現在に至る。2006年より九州大学附属図書館研究開発室員, 国立情報学研究所客員准教授を兼任。2009年より九州大学宙空環境研究センター総合理論解析部門兼任教員。(学術)情報流通とその基盤構築に関する研究としてウェブ・テキスト・時系列データ・マイニング, 認証認可, 情報検索, データベース等の研究に従事。ACM, EATCS に所属。



中村 和幸

2002年東京大学工学部計数工学科卒業, 2004年同大学大学院情報理工学系研究科数理情報学専攻修士課程修了, 2007年総合研究大学院大学複合科学研究科統計科学専攻博士課程修了, 同年科学技術振興界機構CREST研究員, 2008年情報・システム研究機構統計数理研究所特任研究員, 2009年明治大学研究・知財戦略機構特任講師, 2011年明治大学先端数理科学研究科特任講師。日本統計学会, 日本応用数理学会, 地盤工学会, 日本地球惑星科学連合, 日本シミュレーション学会, American Statistical Association に所属。



樋口 知之

1984年東京大学理学部地球物理学科卒業, 1986年東京大学理学系研究科修士課程修了, 1989年同博士課程修了, 同年統計数理研究所予測制御研究系予測理論研究部門助手, 1994年統計数理研究所予測制御研究系予測理論研究部門助教授, 2002年統計数理研究所予測制御研究系システム解析研究部門教授, 2005年統計数理研究所モデリング研究系教授, 予測発見戦略研究センター副所長, 2011年統計数理研究所所長, 現在に至る。専門はベジアンモデリングと時系列解析。日本統計学会, 電子情報通信学会, 人工知能学会, 地球電磁気・地球惑星圏学会, 日本バイオインフォマティクス学会, 日本マーケティング・サイエンス学会, American Statistical Association, International Statistical Institute, American Geophysical Union に所属。



吉川 顕正

1996年九州大学大学院理学研究科物理学専攻単位取得退学, 同年同大学入学選抜情報室・理学部講師, 2001年九州大学理学研究院地球惑星科学部門助教を経て, 2011年より九州大学理学研究院地球惑星科学部門講師(宙空環境研究センター講師 併任), 現在に至る。専門は多圏間結合物理学, 数理太陽地球系科学。地球電磁気・地球惑星圏学会, American Geophysical Union, European Geosciences Union に所属。



魚住 禎司

1991年九州大学理学部物理学科卒業, 2000年同大学大学院理学研究科地球惑星科学専攻博士後期課程修了, 2003年九州大学宙空環境研究センター研究機関研究員(講師), 2004年より九州大学宙空環境研究センター学術研究員, 2001年より九州情報大学非常勤講師, 現在に至る。宙空環境監視のための地磁気観測システムの開発およびオーロラサブストーム発生にともなう地磁気脈動の発生・伝搬機構の研究に従事。地球電磁気・地球惑星圏学会, American Geophysical Union に所属。



藤本 晶子

2005年九州大学理学部地球惑星科学科卒業，2007年同大学大学院理学府地球惑星科学専攻修士課程修了，2010年同大学大学院理学府地球惑星科学専攻博士後期課程修了，同年より宇宙科学研究所宇宙航空プロジェクト研究員，現在に至る．科学衛星搭載用フラックスゲート磁力計の開発および磁気圏における長周期地磁気脈動の生成・伝搬機構の研究に従事．

American Geophysical Union に所属．



森岡 昭

1966年東北大学理学部卒業，1967年第9次南極地域観測隊越冬隊員として昭和基地，1969年東北大学教務技官，1974年東北大学理学部助手，1986年東北大学理学部助教授を経て，1993年より東北大学大学院理学研究科教授，現在に至る．木星高エネルギー粒子の研究および惑星磁気圏電磁現象の研究に従事．地球電磁気・地球惑星圏学会，American Geophysical Union，日本惑星科学会に所属．

Geophysical Union，日本惑星科学会に所属．



湯元 清文

1979年東北大学大学院理学研究科地球物理学専攻博士後期課程中退，同年東北大学理学部助手，1989年名古屋大学空電研究所助教授，1990年名古屋大学太陽地球環境研究所助教授を経て，1996年より九州大学大学院理学研究院教授，2002年より九州大学宙空環境研究センターセンター長，現在に至る．マグダス環太平洋地磁気観測ネットワークを用いた太陽

地球系電磁気現象の研究，FM-CW レーダによる電離層変動電場の観測的研究，国際宇宙天気イニシアティブ（ISWI）事業や CAUSES-II 国際事業の推進および地震前兆としての超低周期地磁気脈動電磁異常現象に関する基礎的調査研究．地球電磁気・地球惑星圏学会，American Geophysical Union，宇宙生物学会，日本天文学会，物理探査学会に所属．