

# カーネル特徴空間における正準角を利用した宇宙機異常検知法

## Anomaly Detection Method for Spacecraft Using Canonical Angle in Kernel Feature Space

藤巻遼平\*1 矢入健久\*2 町田和雄\*2  
Ryohei Fujimaki Takehisa Yairi Kazuo Machida

\*1 東京大学工学系研究科航空宇宙工学専攻 Dept. of Aeronautics and Astronautics, Univ. of Tokyo  
\*2 東京大学先端科学技術センター RCAST, Univ. of Tokyo

This paper proposes an anomaly detection method for spacecraft which uses canonical angles between subspaces in kernel feature space. In recent years, anomaly detection methods based on machine learning and data mining techniques have become more important though the ones based on prior expert knowledge have conventionally been main stream. This paper generalizes the feature, which we defined as the linear combination of principle vectors extracted by kernel PCA, into the subspace in kernel feature space. This causes reformulation of the problem, which results in a generalized eigenvalue problem and constrained nonlinear programming problem. The proposed method monitors a low dimensional subspace in high dimensional kernel feature space, that is, manifold in kernel feature space. We have confirmed the effectiveness of the proposed method by applying it to the telemetry data of simulated spacecraft during a rendezvous process.

### 1. はじめに

高度な異常検知技術の確立は、近年の宇宙機の開発にとって重要な課題の一つである。宇宙機に対する信頼性の要求が高まる一方で、複雑化した宇宙システムには容易に不確定要素が入り込む。さらに、真空、放射線、温度変動など、宇宙環境は宇宙機にとって故障の起こりやすい環境である。また、地上システムとは異なり、地球から遠隔の環境にある宇宙機を異常箇所を直接調査し修理することは困難であるため、システムの挙動に関する異常な兆候を早期に検知し適切な対応をとることが致命的な事故を回避するためには重要となる。

宇宙機異常検知問題では、従来はリミットチェック [DeCoste 97], エキスパートシステム [Ciceri 94, Tallo 92], モデルベース診断システム [Kleer Johann 89, Hutter 03] といった、専門家の事前知識に基づいた手法が提案されてきた。リミットチェックは実装、理解のし易さ、エキスパートシステムおよびモデルベース診断システムは高度な異常検知、診断能力という利点を持つ。しかし、その反面これらの手法は、完全かつ正確なモデルやルール集合が事前に与えられることを前提としているため、宇宙環境の不確実性に対する脆さや専門家からの知識獲得の問題が指摘されている。一方で近年、宇宙機のテレメトリデータに対して機械学習、データマイニングを適用することによって、知識、モデルベースの手法の問題点を補うことが可能であることが複数の研究 [Fujimaki 05a, Yairi 04] によって示されている。筆者らは、このようなアプローチを「テレメトリマイニング」と呼んでいる。

前研究 [Fujimaki 05b] において、筆者らは、「静的な構造を持つシステムから生成されるデータは適切な特徴空間の部分空間に拘束され、その部分空間におけるデータの挙動を監視することでシステムの変調を検知できる」という着想に基づいた異常検知手法を提案した。そこで、この研究では、カーネル特徴空間における主成分ベクトルの線形結合を経験的な特徴量として定義していた。しかし問題を再考すると、主成分ベクトルによって構成される部分空間の変動を監視するほうが、理論的に妥当であり、また前述の着想にもより忠実である。本稿は、

上述のように特徴量を一般化し、正準角を利用した異常度を提案し、その有効性を確認する。

### 2. 提案手法の概念

#### 2.1 仮説と Representative Subspace

宇宙機のテレメトリデータは非常に高次元な時系列データであり、大規模な宇宙機では数千系列に及ぶ。我々は、定常運用する宇宙機が物理法則や制御則によって拘束されていることに着目し、「高次元のテレメトリデータに対して宇宙機の本質的な挙動を表す次元は低次元である」という仮説を立てた。これは言い換えれば、宇宙機はある高次元空間における低次元の部分空間、すなわち多様体上に拘束され運動しているということの意味する。そこで、宇宙機が拘束される多様体の特徴量と定義し、正常に動作する宇宙機のデータから特徴量を抽出し、その変化を監視することで異常を検知するというのが提案手法の概念である。部分空間の学習には、カーネル主成分分析 [Scholkopf 98] を用いる。宇宙機の挙動が拘束される部分空間は、システムノイズによってある部分空間を中心に変動していると考えられる。我々はこの部分空間を *Representative Subspace* (RS) と呼ぶ。

#### 2.2 手法概要

提案手法では、まずテレメトリデータの各系列を要素とする訓練データ  $D = \{x_i\}_{i=1}^N$  を窓長さ  $W$  の Sliding Window [Keogh 01] を適用することで、 $M$  個の訓練データ集合、 $D_j = \{x_w^j\}_{w=1}^W$ , ( $x_w^j \in D, j = 1, \dots, M$ ), を生成する。

次に各  $D_j$  に対してカーネル主成分分析を適用し、カーネル関数によって構成される特徴空間における  $m$  次元の部分空間を抽出する。これらの部分空間の集合を訓練データとして、正常動作時に宇宙機の拘束される部分空間を最もよく表す空間、すなわち *Representative Subspace* を計算する。RS が計算されたら、各  $D_j$  から抽出された部分空間がその周りにどのように分布しているかを、第 2.3 節で定義する異常度の分布として学習する。異常度の計算では空間同士の距離の尺度である正準角を近似して利用する。

運用時には、オンラインで逐次的に得られるデータに対して Sliding Window を適用することで得られるデータセットに kernel PCA を適用し部分空間を抽出する。この部分空間の異

常度がある閾値を超えたときに異常を検知する。

### 2.3 特徴量と異常度

前章で説明したように、本稿ではカーネル特徴空間において宇宙機の拘束される  $m$  次元の部分空間を特徴量とみなす。そこで、まず Sliding Window によって抽出された各データ集合  $\mathcal{D}_j$  に対してカーネル主成分分析 [Scholkopf 98] を適用して第  $m$  主成分までを得る。データ集合  $\mathcal{D}_j$  の第  $k$  主成分ベクトル  $v_k^j$  は、 $v_k^j = \sum_{w=1}^W \alpha_{k,w}^j \tilde{\phi}(x_w^j)$  と表現される。ただし、 $\phi$  はカーネルヒルベルト空間への写像を表し、カーネル関数  $k$  に対して  $\phi(x_w^j) = k(x_w^j, \cdot)$  である。また、 $\tilde{\phi}$  はヒルベルト空間において中心化された写像、 $\tilde{\phi}(x_w^j) = \hat{k}(x_w^j, \cdot) = \phi(x_w^j) - \sum_{w=1}^W \phi(x_w^j)$  を表す。

この時、提案手法における特徴量を以下に定義する（この特徴量の定義は、 $m = 1$  の場合には筆者らが文献 [Fujimaki 05b] で提案した特徴量と一致し、その特徴量を一般化したものであると解釈できる。）。

定義 1 宇宙機のテレメトリデータ  $\mathcal{D}_j = \{x_w^j\}_{w=1}^W$  が与えられたとき、この宇宙機の挙動を現す特徴をカーネル特徴空間上において宇宙機の拘束される  $m$  次元の部分空間と定義し、

$$V^j = \{v_1^j, \dots, v_m^j\}, \quad (1)$$

と表記する。

部分空間  $V^j$  は、数学的には  $v_m^j$  を列ベクトルとする行列  $V^j = [v_1^j \dots v_m^j]$  と等価であり、以後混同の恐れのない場合にはどちらも単に  $V^j$  と表記する。この正常時における  $V^j$  を最もよく表す空間を *Representative Subspace* と呼び、

$$R = [r_1 \dots r_m], \quad (2)$$

と表記する。

RS を基準とした異常度を定義するために、空間の同士の距離として知られる正準角を利用する。今、 $r_k \in R, v_k \in V$  としたとき、二つの空間の間には  $m$  個の正準角が、大きいほうから順に、

$$\cos^2 \theta_k = \max_{r_k \perp r_s, v_k \perp v_s} \frac{|(r_k, v_k)|^2}{\|r_k\|^2 \|v_k\|^2} (s = 1, \dots, k-1). \quad (3)$$

と定義される。ただし、 $\cos \theta_1 > \cos \theta_2 > \dots > \cos \theta_m$  とする。これは、 $R^T V$  の特異値分解によって計算できることが知られている [Chatelin 93]。この正準角を利用して、異常度を以下のように定義する。

定義 2 正常時の代表となる部分空間  $R$  があるとする。この時、テストする部分空間  $V$  の異常度を、

$$\delta = \frac{2}{\pi} \sum_{k=1}^m \nu_k \theta_k, \quad (4)$$

と定義する\*1。ただし、 $\nu_k$  は  $\sum_{k=1}^m \nu_k = 1$  を満たす軸に関する重みで式 (6) で定義する。

### 3. 代表となる部分空間

正常に動作する宇宙機に関する  $M$  個のデータ集合  $\{x_i^j\}_{i,j=1}^{N,M}$  から特徴となる部分空間  $V^j$  を抽出したら、これらの部分空間を最もよく説明する最適な空間 (RS) を計算する必要がある。ただし、部分空間  $V^j$  の基底  $v_k^j = \sum_{i=1}^N \alpha_{ki}^j \tilde{\phi}(x_i^j)$  は  $\tilde{\phi}$  が明示的に与えられていないため、カーネル関数を利用して計算することになる。

まず、RS は正常時の訓練データに対して異常度が最小になるように定義するのが自然であるが、 $R$  の基底の形を与えないと異常度が計算できないため、 $R$  とテストされる部分空間  $V$  の間に定義される正準角を以下で説明するように近似する。

この手法の基となる仮説は、宇宙機の挙動がある部分空間に拘束され、システムノイズなどによってその空間から微小にずれた空間を運動しているというものであった。この仮説に基づけば、カーネル主成分分析によってもとまる第  $k$  固有ベクトルは、超部分空間における  $k$  番目の軸周りに分布するはずである（部分空間は基底の方向が違ったとしても空間としては同一となりうるが、前述したように同一の多様体上に拘束される場合には、分散が最大の方角も一致するはずである）。そこで、我々は  $R$  と  $V$  の間に定義される  $k$  番目の正準角を  $k$  番目の基底のなす角によって近似する\*2。

次に、前述した仮説を考慮して、 $r_k$  を各固有ベクトルの重みつき線形和として、

$$r_k = \sum_j^M w_k^j v_k^j, \quad (5)$$

と表す。この定義から、スケールの問題を回避するために各第  $k$  固有値の比率を  $\lambda_k^j = \lambda_k^j / \sum_{k=1}^m \lambda_k^j$  と置きなおして、それらの平均、

$$\nu_k = \sum_{j=1}^M w_k^j \lambda_k^j, \quad (6)$$

を異常度に関する重みとして提案する。ただし、 $\sum_{k=1}^m \nu_k = 1$  という条件を満たすために、 $\nu_k = \nu_k / \sum_{k=1}^m \nu_k$  と置き換える。このように異常度に関する重みを定義することは定性的には、固有値の比率の大きい軸がずれることをより重視するということを意味する。すなわち、固有値は多様体上における分散の広がり方の大きさを表現し、その比率によって正準角のずれに対して重みをつけていることになる。

このように  $r_k$  を定義すると、各  $k$  に対して最適な重み  $w_k = (w_k^1, \dots, w_k^M)^T$  を計算しなければならない。本来は全訓練データに関する異常度  $\sum_{j=1}^M \delta^j$  を最小とすべきであるが\*3、これを目的関数とすると、目的関数の形が非常に複雑となり最適化の際に局所最小の問題などが生じ、解決することが難しい。そこで、問題を緩和して、第 1 主成分の重み  $\nu_1$  が最も大きいことに注目し、第 1 主成分の基底から重みの大きい順に最適化を行う。ただし、 $k$  が 2 以上の時の繰り返しを避けるため、以下では添え字は  $k$  と表記する。

まず、内積  $\langle r_k, v_k^j \rangle$  の絶対値が大きいほど異常度  $\delta$  が小さくなることを考慮すると、最適化問題は、

$$\arg \max_{\mathbf{r}} \sum_{j=1}^M \langle r_k, v_k^j \rangle^2, \quad (7)$$

\*1 正準角  $\theta_k$  に関しては、 $\theta_k$  と  $\pi - \theta_k$  は成す角度としては同じであるため、最大で  $\pi/2$  となる。  $2/\pi$  をかけることにより、異常度は  $0 \leq \delta \leq 1$  となる。

\*2 簡単のため、両者とも単に  $\theta_k$  と表記する。

\*3  $\delta^j$  は、訓練データに対して Sliding Window を適用して生成された第  $j$  番目のデータ集合に関する異常度。

を,

$$\mathbf{r}_k^T \mathbf{r}_k = 1, \quad (8)$$

という制約条件の下で解くことになる. 式 (5) を式 (7) に代入して,

$$\sum_{j=1}^M \langle \mathbf{r}_k, \mathbf{v}_k^j \rangle^2 = \mathbf{w}_k^T \mathbf{U}_k \mathbf{w}_k. \quad (9)$$

となる. ここで,

$$\mathbf{U}_k^j = \begin{pmatrix} \langle \mathbf{v}_k^1, \mathbf{v}_k^j \rangle \\ \vdots \\ \langle \mathbf{v}_k^M, \mathbf{v}_k^j \rangle \end{pmatrix}, \quad \mathbf{U}_k = \sum_{j=1}^M \mathbf{U}_k^j \mathbf{U}_k^{jT}. \quad (10)$$

としている.

したがって, 最適方向  $\mathbf{r}_{k,opt}$  を計算するための最適化問題は, 最適な重みベクトル  $\mathbf{w}_{k,opt}$  に関する最適化問題,

$$\mathbf{w}_{k,opt} = \arg \max_{\mathbf{w}} \mathbf{w}_k^T \mathbf{U}_k \mathbf{w}_k, \quad (11)$$

を式 (8) の制約の下で解くことになる. ここで,

$$\mathbf{r}_k^T \mathbf{r}_l = \mathbf{w}_k^T \mathbf{A}_{kl} \mathbf{w}_l, \quad (12)$$

かつ,

$$\mathbf{A}_{kl} = \begin{pmatrix} \langle \mathbf{v}_k^1, \mathbf{v}_l^1 \rangle & \cdots & \langle \mathbf{v}_k^1, \mathbf{v}_l^M \rangle \\ \vdots & \ddots & \vdots \\ \langle \mathbf{v}_k^M, \mathbf{v}_l^1 \rangle & \cdots & \langle \mathbf{v}_k^M, \mathbf{v}_l^M \rangle \end{pmatrix} \quad (13)$$

であることに注意して, ラグランジュの未定乗数  $\gamma$  を導入して微分を 0 とすることで式 (11) は,

$$\mathbf{U}_k \mathbf{w}_k = \gamma \mathbf{A}_{kk} \mathbf{w}_k, \quad (14)$$

という一般化固有値問題に帰着する. 最適な重みベクトル  $\mathbf{w}_{k,opt}$  は第一固有ベクトルとなる.

基底  $\mathbf{r}_1$  が求まったら, 順に  $\mathbf{r}_2, \dots, \mathbf{r}_m$  と計算をしていく.  $\mathbf{r}_k$  ( $k = 2, 3, \dots, m$ ) に関する最適化は,  $k = 1$  の場合に  $\mathbf{r}_k^T \mathbf{r}_l = 0$  ( $l = 1, \dots, k-1$ ) という直交の条件が加わる. この最適化問題は,

$$\arg \max_{\mathbf{w}} \mathbf{w}_k^T \mathbf{U}_k \mathbf{w}_k, \quad (15)$$

かつ, 制約条件が,

$$\mathbf{w}_k^T \mathbf{A}_{kk} \mathbf{w}_k = 1, \quad \mathbf{w}_l^T \mathbf{A}_{lk} \mathbf{w}_k = 0, \quad (16)$$

と記述される. これは, 2 次の目的関数に対して 1 次と 2 次の制約条件がつくため逐次二次計画法を利用して解を得ることができる.

代表となる空間  $\mathbf{R}$  が計算されたら, 訓練データ集合から正常動作時の異常度の分布を計算する. 本稿では異常度の分布は, 0 平均の正規分布  $\mathcal{N}(0, \sigma^2)$  に従うと仮定する\*4.

分布が計算されると, 提案手法はオンラインで地上に送信される入力データ集合  $\{\mathbf{x}_i\}_{i=1}^N$  からカーネル主成分分析を用いて部分空間を抽出し異常度  $\delta$  を計算する. この時, 両側確率,

$$\int_{-\infty}^{-\delta} \mathcal{N}(0, \sigma^2) d\delta' + \int_{+\delta}^{+\infty} \mathcal{N}(0, \sigma^2) d\delta'. \quad (17)$$

が, ある閾値  $\varepsilon$  を下回ると異常を検出する. 異常度に関する閾値  $\eta$  は  $\int_{-\infty}^{-\eta} \mathcal{N}(0, \sigma^2) d\delta' + \int_{+\eta}^{+\infty} \mathcal{N}(0, \sigma^2) d\delta' = \varepsilon$  とする.

\*4 実際には異常度は範囲が  $[0, 1]$  となるため正規分布とはならないが, 分散が小さければ 1 より大きい確率密度はほぼ 0 となり, また対称なので負側に関しては考慮しないがよい.

## 4. 実験と考察

### 4.1 実験条件

まず, 多項式カーネル  $k(\mathbf{x}, \mathbf{x}') = \langle \mathbf{x}, \mathbf{x}' \rangle^d$  を用い, 線形空間と非線形空間を比較するために  $d = 1$  および  $d = 2$  に関して比較をおこなった.

本研究に用いた宇宙機ランデブシミュレーションのテレメトリデータは全 27 の時系列から構成され, 13 系列が姿勢制御系 (AOCS), 残りが推進系 (PS) からなる. より詳細には, AOCS は宇宙機の位置と姿勢を表す 12 の実数の観測時系列と 1 つのコマンド列からなる. PS は 16 の離散値をとる時系列からなり, 各系列が宇宙機に搭載された 14 のスラスタへのコマンド入力を表している. 訓練データは正常動作時の 6900 点 (860 秒) を用いた. これを 23 の部分集合 ( $M = 23$ ) に分割した. したがって, それぞれの部分集合は 300 点を含むことになる ( $W = 300$ ).

本実験で ACOS に関しては, 元々の観測値ではなく時刻  $t+1$  と  $t$  との差分値を用いた. これは姿勢制御系に関しては, 一般的に観測値よりも差分値に情報が多く含まれているためである. また, 主成分ベクトルの数  $m$  に関しては, 本研究で利用したデータに関しては第 1 固有値が支配的で, 第 1 固有値と第 2 固有値の占める割合が 95% 程度であったため  $m = 2$  とした. 異常検知の閾値は訓練データの異常度の最大値とした.

次節以降で, 上記のシミュレーションにおいて仮想的に 2 つの故障を発生させ, そのテレメトリデータに対して提案手法を適用し, その有効性を検証する. 故障事例はどちらもピッチ制御に用いられる第 9 スラスタに何らかの異常が起こることを想定している. 両事例とも推力 100% が正常な出力状態とする. また, 比較実験として筆者らが文献 [Fujimaki 05a] で提案する適応的なリミットチェックと性能の比較を行う. 適応的なリミットチェックではターゲット系列を指定する必要があるが, 本実験の故障事例ではピッチ制御用のスラスタに異常が起こるため, ピッチ角をターゲット系列とする.

### 4.2 異常事例 1

この異常事例では, 時刻 250 秒においてスラスタの推力が 0% に低下後, 周期 300 秒の正弦波にしたがって推力が変化する (図 1 下段).

図 1 に結果を示す. 上段は提案手法による異常度の変化 (実線) を表す. 時刻 250 秒において, 異常度がリミット値 (破線) を超え異常の検知に成功していることがわかる. 中段は適応的なリミットチェックにおける尤度の変化 (実線) を表し, 時刻 250 秒でデータの尤度がリミット値を下回り, 異常の検知に成功していることが確認できる. この事例では, 両手法とも異常の発生直後に検知に成功している. また注目すべきことに, 両手法の異常度とスラスタ推力 (下段) の時間変化が類似し, 両手法の結果が一致していることが確認できる. この異常度とスラスタ推力の類似性から, 提案手法は異常検知後の専門家による原因の解析を支援することが可能であると言える.

### 4.3 異常事例 2

この異常事例では, 時刻 250 秒においてスラスタの推力が 30% に低下する (図 2 下段). この事例は, たとえ第 9 スラスタの推力が 30% に低下したとしても, その他のスラスタが推力の不足を補完して制御するために, 事例 1 と比較して異常検知が難しい. 宇宙機の挙動は, 見た目上は制御則が変化したような挙動を示す.

図 2 に結果を示す. このような正常動作時とデータの挙動範囲が大きくは変化しないタイプの異常は, リミットチェックタイプの異常検知法では検知することが難しい. 筆者らの提案す




図 1: 事例 1 に関する提案手法の異常度 (上段) と適応的リミットチェックの尤度 (中段) の変化。

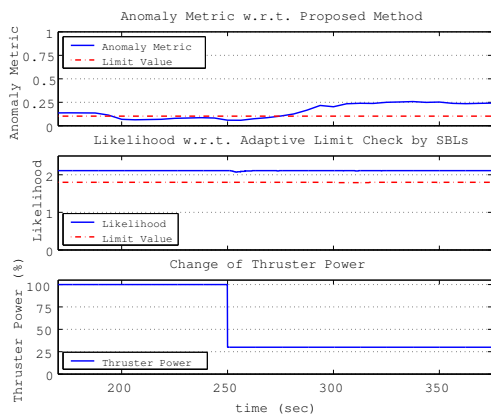


図 2: 事例 1 に関する提案手法の異常度 (上段) と適応的リミットチェックの尤度 (中段) の変化。

る適応的リミットチェックも、データの尤度は異常前後でほとんど変化せず、異常の検知に失敗している (中段)。一方で、提案手法は異常の検知に成功していることが確認できる (上段)。

## 5. 結論

本稿ではカーネル特徴空間における部分空間と正準角を利用した宇宙機の異常検知法を提案した。提案手法は、宇宙機の挙動が高次元特徴空間における部分空間に拘束されているという仮説に基づき、その部分空間を監視することによって異常の検知を行う。我々は、宇宙機のランデブプロセスを模擬したシミュレータのテレメトリデータに対して提案手法を適用し、その有効性を確認した。

我々には以下のような future works がある。まず、提案手法はカーネル特徴空間の性質を利用しているが、専門家がカーネル特徴空間での宇宙機の挙動を理解することは困難である。したがって、専門家による故障原因の解析を支援するために、異常の基となっているテレメトリデータを示すことが重要となる。我々は、この問題に対するアイデアがあり、今後実装し評価を行う予定である。次に、提案手法の利用する部分空間と多様体の関係に関して本文中で定性的な説明を行った。今後、宇宙機の制御則と宇宙機の拘束される多様体の関係に関して、理論的な側面から解析を進めたい。

## 6. ACKNOWLEDGEMENTS

本研究を進めるにあたり、宇宙航空研究開発機構 (JAXA) の山中浩二氏、稲場典康氏には、宇宙機運用の専門家の立場から様々な知見を頂くと共に、データの提供をして頂きました。深く感謝いたします。

## 参考文献

- [Chatelin 93] Chatelin, F.: *Eigenvalues of matrices*, Chichester : Wiley and Sons, New York (1993)
- [Ciceri 94] Ciceri, F. and Marradi, L.: Event Diagnosis and Recovery in Real-time On-board Autonomous Mission Control, in *Proceedings of the 1st Ada-Europe Symposium*, pp. 288–301 (1994)
- [DeCoste 97] DeCoste, D.: Automated Learning and Monitoring of Limit Functions, in *Proceedings of International Symposium on Artificial Intelligence and Robotics and Automation in Space*, pp. 287–292 (1997)
- [Fujimaki 05a] Fujimaki, R., Yairi, T., and Machida, K.: An Anomaly Detection Method for Spacecraft using Relevance Vector Learning, in *Proceedings of The Ninth Pacific-Asia Conference on Knowledge Discovery and Data Mining*, pp. 785–790 (2005)
- [Fujimaki 05b] Fujimaki, R., Yairi, T., and Machida, K.: An Approach to Spacecraft Anomaly Detection Problem Using Kernel Feature Space, in *Proceedings of the 11th ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, pp. 401–410 (2005)
- [Hutter 03] Hutter, F. and Dearden, R.: The Gaussian Particle Filter for Diagnosis of non-linear Systems, in *Proceedings of the 14th International Conference on Principles of Diagnosis*, pp. 65–70 (2003)
- [Keogh 01] Keogh, E. J., Chu, S., Hart, D., and Paz-zani, M. J.: An online algorithm for segmenting time series, in *Proceedings of the IEEE International Conference on Data Mining*, pp. 289–296 (2001)
- [Kleer Johann 89] Kleer Johann, de and Williams, B. C.: Diagnosing with behavioral modes, in *Proceedings of the 11th International Joint Conference on Artificial Intelligence*, pp. 1324–1330 (1989)
- [Scholkopf 98] Scholkopf, B., Smola, A., and Muller, K. R.: Nonlinear component analysis as a kernel eigenvalue problem, *Neural Computation*, Vol. 10, No. 5, pp. 1299–1319 (1998)
- [Tallo 92] Tallo, D. P., Durkin, J., and Petrik, E. J.: Intelligent Fault Isolation and Diagnosis for Communication Satellite Systems, *Telematics and Informatics*, Vol. 9, No. 3-4, pp. 173–190 (1992)
- [Yairi 04] Yairi, T., Kato, Y., and Hori, K.: Fault Detection by Mining Association Rules from House-keeping Data, in *Proceedings of International Symposium on Artificial Intelligence, Robotics and Automation in Space* (2004)