

## 半教師付き能動学習による宇宙機の運用支援法

Operation Support Method for Spacecraft via Semi-Supervised &amp; Active Learning

江藤 力\*<sup>1</sup>

Riki ETO

桑原 絢一\*<sup>1</sup>

Junichi KUWABARA

酒匂 信匡\*<sup>2</sup>

Nobutada SAKO

矢入 健久\*<sup>3</sup>

Takehisa YAIRI

\*<sup>1</sup>東京大学大学院 航空宇宙工学専攻

Dept. of Aeronautics and Astronautics, Univ. of Tokyo

\*<sup>2</sup>信州大学大学院 電気電子工学専攻

Dept. of Electrical and Electronic Engineering, Shinsyu Univ.

\*<sup>3</sup>東京大学 先端科学技術研究センター

Research Center for Advanced Science and Technology, Univ. of Tokyo

In this paper we propose an operation support method which applies machine learning techniques to telemetry data of spacecraft for anomaly analysis and improvement of the mission's success rate. Generally, machine learning approaches applied to complex systems such as spacecraft for anomaly analysis need many labeled data and will be a time-consuming task. So, we use semi-supervised learning method that can analyze with less data to save time for collect labeled data. In addition, we actively collect valuable labeled data and calculate the mission's success rate to perform efficient operation. We have confirmed the effectiveness of the proposed framework by applying it to the telemetry data of a small artificial satellite launched by Univ. of Tokyo.

## 1. はじめに

国際宇宙ステーションや GPS に代表される宇宙の開発や利用が日常化している近年においても、宇宙機の開発・製造コストが莫大であることや打ち上げ機会の希少性は解消されておらず、宇宙システムに課せられたミッションの成功は至上命題となっている。また宇宙空間という厳しい環境に曝されるため、その故障や不具合をゼロにすることは容易ではなく、一度故障すると修復は困難であるので、故障率を抑える製造技術のみならず運用による不具合の早期発見と対策が重要だといえる。

宇宙機のような複雑な工学システムの異常診断は、専門家の経験的な知識に基づいた演繹的な手法が主流であるが、事前の想定が困難な異常現象を正確に記述することは難しい。これに対し最近では、データから帰納的に背後構造を獲得する機械学習と、それを知識発見プロセスに組み込み大量のデータから有益な情報を抽出するデータマイニングを異常診断に用いることが提案されている [Kawahara 05]。しかし、その瞬間のラベル（正常か異常か）が分かっているデータ（ラベルありデータ）の収集に時間がかかり、設計寿命が数年単位の宇宙機において望まれる早期の異常診断を実行できない恐れがある。

宇宙機はテレメトリデータという機体内の電流、温度等の各状態を計測したものを絶えず記録していることから、データの分布情報も考慮する半教師あり学習を容易に用いることができる。また宇宙機は運用者が制御するものであり、かつ運用コストが高いので、学習効果が高い新たなラベルありデータを能動的に選択・収集する能動学習が効果的である。

よって、本稿では半教師付き能動学習 [Qiuhua 08] の手法を拡張した枠組みを提案する。まず半教師あり学習を用いて、少数のラベルありデータとデータの分布情報による早期の異常診断を行う。そして、得られたデータとラベルの相関関係から運用時のミッション成功確率の算出し、ミッション運用時の指標として提示する。また運用に余裕がある際には、能動学習により最適な学習を行うことで効率的な運用を支援する。

連絡先: 江藤 力, 東京大学大学院 航空宇宙工学専攻, 東京都目黒区駒場 4-6-1 東京大学先端科学技術研究センター  
e-mail: r\_eto@space.rcast.u-tokyo.ac.jp

## 2. 解析対象

本稿では、超小型人工衛星 XI-V [Yuliang 05] の撮像ノイズ問題を探り上げる。XI-V は、2005 年 10 月に地球周回軌道へと投入された 10 センチ立方 1 キログラムの衛星であり、各壁面を  $\pm X, \pm Y, \pm Z$  で表すと、その  $+X$  面に搭載されたカメラによる撮影画像に縞模様が生じる異常が起きている。この原因を特定し、カメラ運用時の成功率をあげることを目標とする。図 1, 2 にそれぞれ正常時と異常時の画像例を示す。

解析に用いるテレメトリデータとして、太陽電池電圧、各壁面発電電流 ( $\pm X, -Y, +Z$ )、各壁面温度 ( $\pm X, \pm Y, \pm Z$ )、電池温度の計 12 種類の数値が利用可能であり、正常時また異常時に対応するラベルありデータはそれぞれ 6 個, 11 個である。

## 3. 異常診断手法

## 3.1 ロジスティック回帰による異常診断

データ空間上において、正常と異常というラベルごとにデータが別のクラスタとして分布していると仮定すれば、その分離超平面的法線方向がラベルの差異を生むといえる。今回は、ラベルありデータが少ないため線形境界を用いることとし、また外れ値へのロバスト性を期待して、確率的に尤もらしい線形境界を引くロジスティック回帰 (LR) を用いる。

このとき、バイアス成分 1 を加えた正規化データの  $d$  次元列ベクトル  $x_i$  と最適化パラメータ  $\theta$  に対するラベル  $y_i \in \{-1, 1\}$  の確率は

$$p(y_i|x_i, \theta) = \frac{1}{1 + \exp(-y_i \theta^T x_i)} \quad (1)$$





図 1: 縞なし (正常) 画像例 図 2: 縞あり (異常) 画像例

であり、これが境界上を表すとき確率は 0.5 なので、

$$\theta^T x_i = 0 \quad (2)$$

として境界面の方程式が得られ、その法線方向は  $\theta$  であることが分かる。よって、ラベル  $y_i$  に対して  $-1$ : 正常,  $1$ : 異常とすれば  $\theta$  は正常クラスから異常クラスへ向かうベクトルとなり、比較的大きな絶対値をもつ成分が異常の原因だといえる。表 1 に反復重みつき最小二乗法 (IRLS) で LR を解いて最適化した  $\theta$  を正規化したものを示す。なお leave-one-out 法により求めた分類器の性能を調べると、正答率 40% であり過学習を起こしていると考えられる。

表 1: LR による原因方向ベクトル

太陽電池電圧	+X 発電電流	-X 発電電流	-Y 発電電流
-0.333	-0.109	-0.105	-0.216
+Z 発電電流	+X 壁温度	-X 壁温度	+Y 壁温度
0.235	0.022	0.037	0.311
-Y 壁温度	+Z 壁温度	-Z 壁温度	電池温度
-0.334	-0.623	-0.355	0.104

### 3.2 スパース LR による異常診断

ここでは LR の過学習を防ぐため、階層ベイズ法を用いて  $\theta$  のスパース化を行う。まず事前分布として下記を導入する。

$$p(\theta|\Lambda) = \frac{|\Lambda|^{1/2}}{(2\pi)^{d/2}} \exp\left(-\frac{1}{2}\theta^T \Lambda \theta\right) \quad (3)$$

$$p(\Lambda|\alpha, \beta) = \prod_{i=1}^d \text{Gamma}(\lambda_i|\alpha_i, \beta_i) \quad (4)$$

なお  $\Lambda = \text{diag}\{\lambda_1, \lambda_2, \dots, \lambda_d\}$  であり、 $\alpha, \beta$  はそれぞれ  $d$  次元ベクトル、また  $\text{Gamma}(\cdot)$  はガンマ分布を表す。よって、(3),(4) 式から  $\Lambda$  を周辺化すれば、

$$p(\theta|\alpha, \beta) = \int p(\theta|\Lambda)p(\Lambda|\alpha, \beta)d\Lambda \quad (5)$$

となり、ラベルありデータの添字集合を  $\mathcal{L} \subseteq \{1, 2, \dots, n\}$  とおくと MAP 推定の評価関数は以下の形で与えられる。

$$\begin{aligned} \ell(\theta) &\stackrel{\text{def}}{=} \ln p(\theta|\alpha, \beta, \{y_i, x_i : i \in \mathcal{L}\}) + \text{const} \\ &= \sum_{i \in \mathcal{L}} \ln p(y_i|x_i, \theta) + \ln \int p(\theta|\Lambda)p(\Lambda|\alpha, \beta)d\Lambda \end{aligned} \quad (6)$$

上式の最大化は、第 2 項にイェンゼンの不等式を用いることで

$$\begin{aligned} \ell(\theta) &\geq \mathcal{Q}(\theta|q) \stackrel{\text{def}}{=} \sum_{i \in \mathcal{L}} \ln p(y_i|x_i, \theta) \\ &\quad + \int q(\Lambda) \ln \frac{p(\theta|\Lambda)p(\Lambda|\alpha, \beta)}{q(\Lambda)} d\Lambda \end{aligned} \quad (7)$$

として  $\ell(\theta)$  の下界:  $\mathcal{Q}(\theta|q)$  を導き、これを EM アルゴリズムで最大化する。なお  $q$  は次式で与えられる。

$$q(\Lambda) = \frac{p(\theta|\Lambda)p(\Lambda|\alpha, \beta)}{\int p(\theta|\Lambda)p(\Lambda|\alpha, \beta)d\Lambda} \quad (8)$$

よって、EM アルゴリズムは以下の 2 ステップ:

1. E-step: computing  $q(\Lambda)$  using (8);
2. M-step: computing the reestimate of  $\theta$  as

$$\theta = \arg \max_{\theta} \mathcal{Q}(\theta|q) \quad (9)$$

を  $\theta$  が収束解を得るまで反復させれば良い。また  $p(\Lambda|\alpha, \beta)$  と  $p(\theta|\Lambda)$  の形から、 $q(\Lambda)$  の  $\exp$  の中身が  $\{-\lambda_i(\beta_i + \frac{1}{2}\theta_i^2)\}$  となるので、Gamma 分布を考慮して

$$q(\Lambda) = \prod_{i=1}^d \text{Gamma}(\lambda_i|\alpha_i + \frac{1}{2}, \beta_i + \frac{1}{2}\theta_i^2) \quad (10)$$

と表せ、M-step では  $dq/d\theta = 0$  なので、(7) 式第 2 項において  $\hat{\theta}$  に関与する部分は

$$\begin{aligned} &\int q(\Lambda)p(\hat{\theta}|\Lambda)d\Lambda \\ &= \int \prod_{i=1}^d \text{Gamma}(\lambda_i|\alpha_i + \frac{1}{2}, \beta_i + \frac{1}{2}\theta_i^2) \left\{-\frac{1}{2}\hat{\theta}^T \Lambda \hat{\theta}\right\} d\Lambda \\ &= -\frac{1}{2}\hat{\theta}^T \text{diag}\{E_q(\lambda_1), \dots, E_q(\lambda_d)\}\hat{\theta} + \text{const} \end{aligned} \quad (11)$$

$$E_q(\lambda_i) \stackrel{\text{def}}{=} \frac{\alpha_i + \frac{1}{2}}{\beta_i + \frac{1}{2}\theta_i^2} \quad (12)$$

となるから  $\gamma = \text{diag}\{E_q(\lambda_1), \dots, E_q(\lambda_d)\}$  とすると、(9) 式は

$$\frac{d\mathcal{Q}(\hat{\theta}|q)}{d\hat{\theta}} = 0 \Leftrightarrow \theta = \gamma^{-1} \sum_{i \in \mathcal{L}} \frac{y_i x_i \exp(-y_i \theta^T x_i)}{1 + \exp(-y_i \theta^T x_i)} \quad (13)$$

を用いればよいことが分かる。なお、 $\theta$  がスパースになる理由は (6) 式第 2 項において  $q(\Lambda)$  の定義を用いれば

$$\begin{aligned} &\int p(\theta|\Lambda)p(\Lambda|\alpha, \beta)d\Lambda = q(\Lambda)^{-1}p(\theta|\Lambda)p(\Lambda|\alpha, \beta) \\ &= \frac{1}{(2\pi)^{d/2}} \prod_{i=1}^d \frac{\beta_i^{\alpha_i}}{\Gamma(\alpha_i)} \frac{\Gamma(\alpha_i + \frac{1}{2})}{(\beta_i + \frac{1}{2}\theta_i^2)^{\alpha_i + \frac{1}{2}}} \end{aligned} \quad (14)$$

となり、MAP 推定時に  $\theta_i$  を小さくしようとするからである。

$\alpha_i = 2.0, \beta_i = 0.1(1 \leq i \leq 13)$  という条件下でのスパース LR による  $\theta$  を正規化したものを表 2 に示す。なお leave-one-out 能を調べると、正答率 65% でありスパース化によって汎化性能が向上したといえる。

表 2: スパース LR による原因方向ベクトル

太陽電池電圧	+X 発電電流	-X 発電電流	-Y 発電電流
0.229	-0.578	0.115	-0.016
+Z 発電電流	+X 壁温度	-X 壁温度	+Y 壁温度
0.301	-0.391	-0.092	-0.285
-Y 壁温度	+Z 壁温度	-Z 壁温度	電池温度
-0.227	-0.266	-0.058	-0.382

### 3.3 半教師ありスパース LR による異常診断

スパース LR の leave-one-out 性能をさらに向上させるため、半教師あり学習を導入する。半教師あり学習とは、入力データの生成構造を考慮することで性能向上を図る教師あり学習の一種である。まず、すべてのデータ点が互いのラベルに対して距離に応じた影響を与えようと仮定する。その際 2 点  $x_i, x_j$  の類似度を動径基底関数 (RBF) を用いて

$$w_{ij} = \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma_i^2}\right) \quad (15)$$

と表し、これを  $(i, j)$  成分として持つ行列を  $W$  とする。そして類似度グラフを確率的に解釈するため、次式で正規化したものをその  $(i, j)$  成分とするマルコフ遷移行列  $A = [a_{ij}]_{N \times N}$  を設定する。ここではデータ点の総数を  $N$  としている。

$$a_{ij} = \frac{w_{ij}}{\sum_{k=1}^N w_{ik}} \quad (16)$$

$A^t = [a_{ij}^{(t)}]_{N \times N}$  は、その  $(i, j)$  成分がランダムウォーク  $t$ -step 後に  $x_j$  から  $x_i$  へ移る確率を表しており、教師あり学習器  $p(y_i|x_i)$  が  $x_i$  からラベル  $y_i$  を出力する確率を表すのに対し、

$$p(y_i|\mathcal{N}_t(x_i)) = \sum_{j=1}^N a_{ij}^{(t)} p(y_i|x_j) \quad (17)$$

は  $\mathcal{X}$  から  $y_i$  を出力する際の半教師あり学習器となる。ここで、 $\mathcal{N}_t(x_i)$  はランダムウォーク  $t$ -step 後に  $x_i$  へ移る  $\mathcal{X}$  の部分集合を表し、 $\sigma_i, t$  でそれら进行操作することでラベル  $y_i$  に対する  $\mathcal{X}$  の影響度を調節する。

この学習器にスパース LR を用いると、(6) 式に対応する MAP 推定の評価関数は

$$\begin{aligned} \tilde{\ell}(\theta) &\stackrel{\text{def}}{=} \ln p(\theta|\alpha, \beta, \{y_i, \mathcal{N}_t(x_i) : i \in \mathcal{L}\}) + \text{const} \\ &= \sum_{i \in \mathcal{L}} \ln \sum_{j=1}^N a_{ij}^{(t)} p(y_i|x_j, \theta) + \ln \int p(\theta|\Lambda) p(\Lambda|\alpha, \beta) d\Lambda \end{aligned} \quad (18)$$

となり、これを最大化するため (6) 式の場合とは異なり、第 1 項にもイェンゼンの不等式を用いる。すなわち、

$$\begin{aligned} \tilde{\ell}(\theta) &\geq \tilde{Q}(\theta|\delta, q) \stackrel{\text{def}}{=} \sum_{i \in \mathcal{L}} \sum_{j=1}^N \delta_{ij} \ln \frac{a_{ij}^{(t)} p(y_i|x_j, \theta)}{\delta_{ij}} \\ &\quad + \int q(\Lambda) \ln \frac{p(\theta|\Lambda) p(\Lambda|\alpha, \beta)}{q(\Lambda)} d\Lambda \end{aligned} \quad (19)$$

として  $\tilde{\ell}(\theta)$  の下界:  $\tilde{Q}(\theta|\delta, q)$  を導き、これを EM アルゴリズムで最大化する。なお  $\delta$  は次式で与えられる。

$$\delta_{ij} = \frac{a_{ij}^{(t)} p(y_i|x_j, \theta)}{\sum_{k=1}^N a_{ik}^{(t)} p(y_i|x_k, \theta)} \quad (20)$$

よって、用いる EM アルゴリズムはスパース LR でのものに対し E-step では  $\delta_{ij}$  も算出し、M-step ではその最適化更新式を下記のものに変更すればよい。

$$\frac{d\tilde{Q}(\hat{\theta}|q)}{d\hat{\theta}} = 0 \Leftrightarrow \hat{\theta} = \gamma^{-1} \sum_{i \in \mathcal{L}} \sum_{j=1}^N \delta_{ij} \frac{y_i x_i \exp(-y_i \theta^T x_i)}{1 + \exp(-y_i \theta^T x_i)} \quad (21)$$

半教師あり学習はデータの分布情報から、その密な部分に重みをおくことで汎化性能を向上させるが、誤った分布情報によって性能が劣化する場合もある。本稿における解析対象は 12 変数なので、(15) 式で定義した類似度において分類に寄与する成分のみでは遠い点同士でも、寄与しない成分によって、近いと見なされてしまう可能性もある。このため、ある程度分布情報として用いる変数を絞り込む必要がある。また、正常か異常かどちらか分からないデータ (ラベルなしデータ) の分布も考慮すれば、更なる汎化性能の向上も可能であるが、今回のラベルありデータはラベルなしデータ分布から一様にサンプリングされたわけではないので leave-one-out 性能は向上しなかった。よって、LR による原因方向ベクトルで一番大きな絶対値を持った +Z 面壁温度のみで類似度を求めた場合が最も leave-one-out 性能が良く、 $\sigma_i = 3.0, t = 1.0, \alpha_i = 2.0, \beta_i = 0.1 (1 \leq i \leq 13)$  という条件下で正答率 82% まで向上した。なおその条件下で半教師ありスパース LR による  $\theta$  を正規化したものを表 3 に示す。

表 3: 半教師ありスパース LR による原因方向ベクトル

太陽電池電圧	+X 発電電流	-X 発電電流	-Y 発電電流
0.274	-0.528	0.212	-0.142
+Z 発電電流	+X 壁温度	-X 壁温度	+Y 壁温度
0.278	-0.400	-0.057	-0.159
-Y 壁温度	+Z 壁温度	-Z 壁温度	電池温度
-0.276	-0.271	-0.107	-0.393

### 3.4 診断結果の解釈

異常診断の結果、カメラ画像に縞が生じる現象は +X 発電電流に強い負の相関があるといえる。また、尤度のみを考慮した通常の LR では +Z 壁温度成分が特に大きな値をもつが、スパース化を施すと目立たなくなる。これは機体が小さいため伝熱による各温度の共変性が強く、スパース化によって他の温度が抑えられるあおりを受けて +Z 壁温度成分も小さな値に留まってしまったと考えられる。よって、+Z 壁温度も異常原因として考慮すると、+X, +Z 面の温度が低いと縞が生じるといえ、衛星内の機器配置ではカメラモジュールが +X, +Z 面近くにあることから、カメラモジュールが低温状態だと縞が生じると推測でき、この結果は衛星の地上試験結果と一致する。

## 4. ミッション成功確率の算出

異常診断の結果から、ラベルありデータの +X 発電電流と +Z 壁温度の 2 変数のみを用いて  $\sigma_i = 3.0, t = 1.0, \alpha_i = 2.0, \beta_i = 0.1 (1 \leq i \leq 3)$  という条件下で、上記 2 変数の分布を考慮した半教師ありスパース LR を行い leave-one-out 性能を調べると正答率 82% に達した。よってこの分類器を用いて運用時のカメラミッション成功確率を算出し、それを判断指標にすれば効率的なミッション運用が可能になるとと思われる。なお、(22) 式は正規化した計測値を用いた  $[+X \text{ 発電電流}, +Z \text{ 壁温度}]^T$  を  $x$  とした時の成功確率であり、図 3 は 2005/12/19 の 3:40 ~ 16:01 における約 4 分毎のテレメトリデータに対して、カメラミッション成功確率を算出した結果である。

$$p_s(x) = \frac{1}{1 + \exp(\theta_s^T x)} \quad (22)$$

$$\theta_s = [0.0848872, -0.19488144, -0.07192911]^T \quad (23)$$

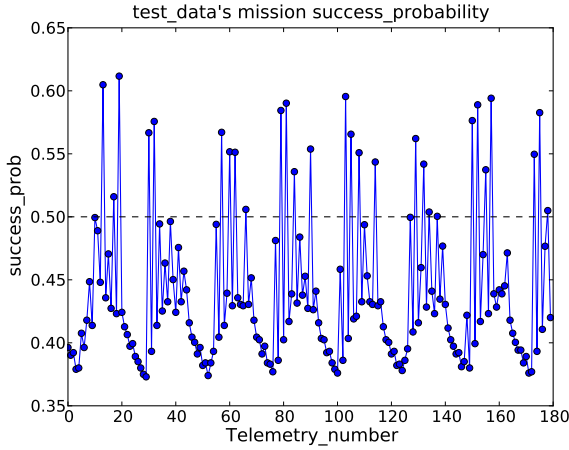


図 3: ミッション成功確率算出例

## 5. 能動学習による実験計画

### 5.1 相互情報量の導入

能動学習とは、学習効果の高いデータの選択手法である。ここでは学習時に用いた  $\theta$  の事後分布における分散を基準として、新たな入力データを決定する。まず、データセット集合  $\mathcal{D}$  の条件付き事後分布  $p(\theta|\mathcal{D})$  にラプラス近似を施し次式を得る。

$$p(\theta|\mathcal{D}) \simeq \mathcal{N}(\theta|\hat{\theta}, H^{-1}) \quad (24)$$

ここで  $\mathcal{N}(\cdot)$  はガウス分布であり、その精度行列  $H$  は

$$H = \nabla^2(-\ln p(\theta|\{y_i, \mathcal{N}_t(x_i)\} : i \in \mathcal{L})) \quad (25)$$

と表せる。これより、新たなラベルありデータ  $x_*$  が得られたときの精度行列  $H'$  は

$$H' = H + p(y|x_*, \theta)\{1 - p(y|x_*, \theta)\}x_*x_*^T \quad (26)$$

となるので、 $x_*$  の事後分布に対する相互情報量  $I$  は

$$\begin{aligned} I &= \frac{1}{2} \ln \frac{|H'|}{|H|} \\ &= \frac{1}{2} \ln [1 + p(y|x_*, \theta)\{1 - p(y|x_*, \theta)\}x_*^T H^{-1} x_*] \quad (27) \end{aligned}$$

であり、これを最大化する  $x_*$  を探索すればよい。

### 5.2 等式制約条件下での能動学習

相互情報量を最大化する学習点の探索空間は、 $x_*$  の成分全体ではなく bias 項を 1 と固定して行わなければならない。また、軌道変更ができない宇宙機では現在の軌道で達成可能な学習点である必要がある。よって  $x_*$  の成分で固定のものを  $x_c$ 、探索する成分を  $x_v$  として、 $x_* = [x_c^T, x_v^T]^T$  とし、それに合わせて各行列を  $x_*$  に対応するように並び替えて、 $x_c, x_v$  に関する部分の添字をそれぞれ  $c, v$  とすれば

$$x_v = \arg \max_{\hat{x}_v} I(\hat{x}_v) \quad (28)$$

となり、 $dI/d\hat{x}_v = 0$  から下記の最適化更新式を導出できる。

$$x_v = \frac{1 - \exp(-\theta_v^T x_v + c_1)}{1 + \exp(-\theta_v^T x_v + c_1)} \frac{x_v^T J_v x_v + c_2}{2} J_v^{-1} \theta_v - \frac{J_v^{-1}}{2} c_3 \quad (29)$$

ただし、 $H^{-1}$  は対称行列なので

$$H^{-1} = \left[ \begin{array}{c|c} J_c & K^T \\ \hline K & J_v \end{array} \right] \quad (30)$$

として、(29) 式の  $c_1, c_2, c_3$  は下記のように表される。

$$c_1 = -\theta_c^T x_c \quad (31)$$

$$c_2 = x_c^T J_c x_c + 2x_v^T K x_c \quad (32)$$

$$c_3 = 2K x_c \quad (33)$$

よって、ラベルありデータで学習後の最適学習点  $x_* = [1, x_v^T]^T$  を求めると、表 4 に示すものが得られた。最適学習点は、現時点の分類器では曖昧な境界付近の点を選ばれる傾向がある。

表 4: 能動学習による最適学習点例

太陽電池電圧	+X 発電電流	-X 発電電流	-Y 発電電流
4.7	33.2	22.6	37.3
+Z 発電電流	+X 壁温度	-X 壁温度	+Y 壁温度
61.9	16.6	26.7	13.6
-Y 壁温度	+Z 壁温度	-Z 壁温度	電池温度
21.3	18.3	15.0	20.0

## 6. おわりに

本稿では宇宙機の異常現象に対して、半教師ありスパースロジスティック回帰による早期の異常診断とその結果を利用したミッション成功確率の算出や、相互情報量最大化に基づく能動学習を行うことで運用の効率化を支援する枠組みを提案し、超小型衛星の撮像ノイズ問題に適用した。その結果、カメラモジュールが低温状態において縞が生じると推論でき、これは衛星の地上試験結果と一致するものである。今後は実機による能動学習の軌道上実証実験を行っていきたいと考えている。

## 参考文献

- [Yuliang 05] Yuliang, Nakada, K., Nojiri, Y., Sasaki, F., Funane, T., Eishima, T., and Nakasuka, S.: Technology Demonstration On University Of Tokyo 's Pico-Satellite " XI-V " and Its Effective Operation Result Using Ground Station Network, International Astronautical Congress (2005)
- [Kawahara 05] Kawahara, N., Yairi, T., and Machida, K.: Spacecraft Diagnosis Using Dynamic Bayesian Networks, The 19th Annual Conference of the Japanese Society for Artificial Intelligence (2005)
- [Qihua 08] Qihua, L., Xuejun L., and Lawrence, C.: Detection of Unexploded Ordnance via Efficient Semisupervised and Active Learning, IEEE TRANSACTIONS ON GEOSCIENCE AND REMOTE SENSING, Vol. 46, No. 9, pp. 2558-2567 (2008)