

機械学習を用いた宇宙機の故障の予兆検知

梅津 里香*¹, 杉江 卓哉*¹, 長瀬 雅之*¹, 湖海 亮*¹,
竹島 敏明*², 海老沢 研*², 満田 和久*², 山本 幸生*²

Detection of failure sign of spacecraft using machine learning

Rika Umezu*¹, Takuya Sugie*¹, Masayuki Nagase*¹, Ryo Kokai*¹,
Toshiaki Takeshima*², Ken Ebisawa*², Kazuhisa Mitsuda*² and Yukio Yamamoto*²

Abstract

Safety and reliability of the spacecraft are very important. It is desirable to predict possible failures of a spacecraft in advance and to have an operational environment leading to accident prevention. By applying failure analysis utilizing machine learning technology to the operation data of a spacecraft, we accumulate techniques to detect defects beforehand and are doing research to contribute to stable operation of the spacecraft. We tried to detect a sign of failure of the power supply using operational data of the X-ray astronomical satellite "Suzaku". As a result, we suggest that it is possible to detect a sign of failure under certain conditions.

Keywords: machine learning, failure analysis, spacecraft, Suzaku

概要

宇宙機は安全性や信頼性が厳しく問われ、未然に危険を予知し、事故防止に繋げる運用環境が望まれる。宇宙機の運用データに機械学習の技術を適用して故障解析を行い、不具合を未然に検知する技術を蓄積し、安定した宇宙機運用に資するための研究を行っている。

X線天文衛星「すざく」の運用データを用いた電源系機器の故障の予兆検知を試み、一定条件下での故障の予兆を検出することが可能であることを確認した。

1. はじめに

宇宙機は一度宇宙に打ち上げると修理を行うことが難しいため安全性、信頼性が厳しく問われる。そのため、日々の運用において未然に危険を予知し、事故防止に繋げる運用環境が望まれる。宇宙機は10年以上の長期運用が行われる場合も多く、宇宙環境という過酷な環境に晒される中で、運用中に故障する機器が少なくない。宇宙機の異常や故障の予兆を早期に検出することは、

doi: 10.20637/JAXA-RR-18-008/0002

* 平成30年12月19日受付 (Received December 19, 2018)

¹ 株式会社セック (Systems Engineering Consultants Co., LTD.)

² 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)

安定運用のための重要な要件である。

長期運用される宇宙機には、膨大な運用データ・観測データが存在する。膨大なデータから得られる運用中に発生した出来事と運用データの関係性を学習することで、機器の故障を事前に捉えられる可能性があると考えられる。

本研究では、X 線天文衛星「すざく」の運用データを使用し、電源系機器に焦点をあてて故障の予兆の早期検出を試みた。

2. 対象データ

故障の予兆検知を行い、その有用性を検証するには、運用中の機器のセンシングデータが存在することや異常発生を表す情報が記録として残っていること等の条件がある。これらの条件を満たし、かつ、約 10 年間の運用により十分なデータが溜まっている X 線天文衛星「すざく」を故障の予兆検知の対象とした（表 1）。

表 1. X 線天文衛星「すざく」基本情報

打ち上げ	2005 年 7 月 10 日
科学観測終了	2015 年 8 月 26 日
軌道	高度 550km, 傾斜角 31 度の円軌道
軌道周期	約 96 分



図 1. すざく衛星及び関連システムから得られるデータの構成

衛星から得られるデータには、図 1 のように HK (HouseKeeping) データや検出機器毎の観測データなどがあるが、それらのほぼ全てが DARTS [1]上で公開されている。また、すざくのホームページ [2]上では運用担当者による当時の運用ログ、観測ログを確認することも可能である。運用、観測のログからは SAFEHOLD (何らかの原因で異常が発生した場合、熱電氣的に安全な姿勢を保持するモード) が発生した原因を確認することができる。これらのログを調査することで、電源系機器の異常が原因と見られる SAFEHOLD を 7 箇所特定した。

運用期間中のバッテリー電圧と、電源系機器の異常が原因と考えられる SAFEHOLD のタイミングを示したものが図 2 である。打ち上げ後から 2012 年直前までは、バッテリーの電圧値が安定的に推移しているが、2012 年以後は、値が不安定になっていることが読み取れる。実際、太陽電池の発生電力が打ち上げから 7 年目に急激に低下したことがすざく衛星の観測運用終了に至る経緯の中に記されている [3]。そこには、観測運用終了に至った経緯としてバッテリーの劣化が一要因として挙げられている。よって、バッテリーの故障の予兆を検知することは宇宙機にとって重要なことである。

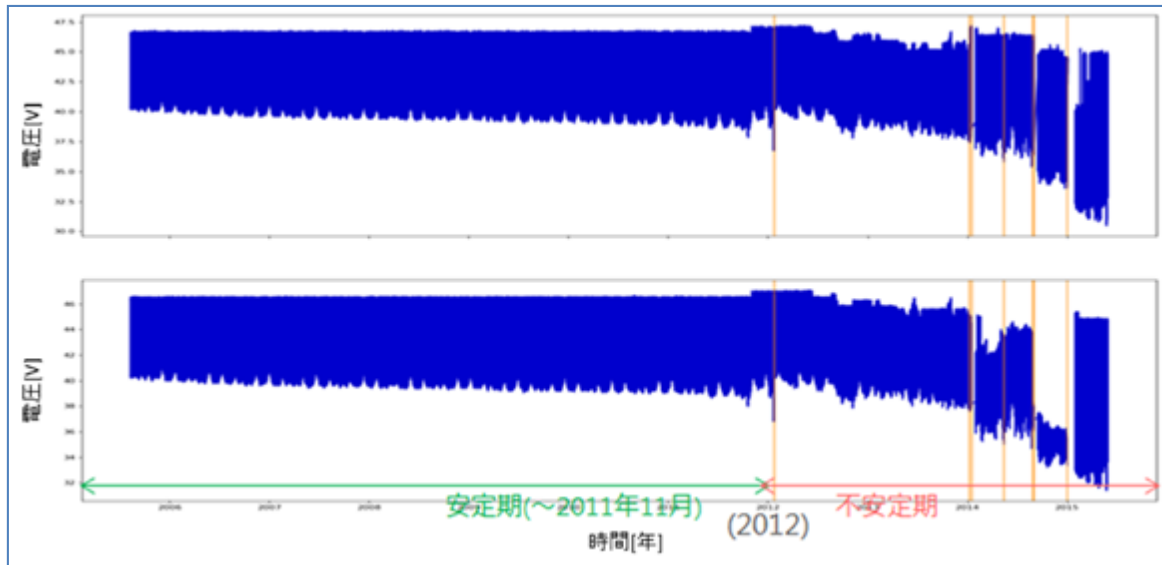


図 2. バッテリー電圧と電源起因の SAFEHOLD

(上: バッテリー A 電圧, 下: バッテリー B 電圧, 橙線が電源系機器起因の SAFEHOLD)

表 2. SAFEHOLD 発生時刻

No.	SAFEHOLD 時刻
1	2012-01-24 01:27:46
2	2014-01-09 18:39:19
3	2014-01-16 19:21:00
4	2014-05-15 20:26:00
5	2014-08-28 04:27:06
6	2014-09-04 00:11:21
7	2015-01-03 07:59:00

すざく衛星の運用中に発生した SAFEHOLD のうち、電源系機器の異常が原因と見られる SAFEHOLD を表 2 にまとめた。この計 7 回の SAFEHOLD の発生をできる限り早期に検出することを目標とする。

2011 年 12 月以降は、バッテリーの状態が常時不安定となっており、バッテリーの使用方法についても工夫がなされ、頻繁にモードが変更されていた。先行研究 [4] を参考に運用期間を安定期フェーズ (~2011 年 12 月) と不安定期フェーズ (2011 年 12 月~) の 2 つに分け、不安定期に入り始めたタイミングの SAFEHOLD を検

出することを重視して確認を行う。

SAFEHOLD 発生の予兆を検出するための手法として機械学習を用いた。機械学習は、大量のデータの中に潜んでいる傾向を学習によって導き出し、得られた学習結果に新たなデータを投入して将来の予測をする手法である。学習はバッテリーの電圧や電流、太陽電池の温度など電源系機器に関わる様々な HK データを組み合わせで行った。評価は学習済みモデルを使用して予測を行った際の予測誤差を故障の予兆とみなして実施した。そのうち有用な結果が得られた 2 系統のバッテリー電圧・温度の計 4 項目のデータを利用した学習結果を以降に示す。

3. 異常検知手法

文献 [5] [6] [7] や先行研究 [8] [9] [10] を参考に今回の課題に適合する異常検知手法を選定して評価を行った。その中で、不安定期の最初の異常を検出可能であった 4 つの手法について概要を

示す。また、どの程度異常であるかを示す値（異常度）の算出方法についても合わせて示す。

その前に、各手法共通で実施するデータ前処理と学習データの抽出方法について説明する。

異常検知に用いるデータには欠損値が存在し、また、電圧と温度で出力されるタイミングが異なるため学習前にデータを整形する必要がある。そのため、事前に線形補間を行い、一定間隔で均一にリサンプリングしている。欠損の間隔が大きい場合はその期間のデータは対象外とした。

電源系機器は常時稼動しているため常に消耗している。10年という長期間にわたって連続稼動する過程で、正常時のデータの分布範囲も時間と共に変化していく。そのため、最初の期間の学習データを使用し続けていると、正常時でも徐々に異常度が高くなってしまふ。これを避けるため、各手法では、月が替わる毎に直近1月前のデータ（約60,000点）を訓練データとして学習し直している。例を図3に示す。なお、SAFEHOLDが発生した異常時のデータは学習から除外している。




図 3. 学習・評価の算出例

3.1 kNN を用いた異常検知

kNN (K Nearest Neighbor, k 近傍法) は、k 個の近傍との距離をもとに近い点は同じグループに属するという考えからクラス分類に使用される手法である。今回は、最近傍のデータとの距離を測定するために用いている。また、kNN は傾向を学習するのではなく、1点1点との距離を測定するため、最近傍との距離の算出に時間がかかる手法である。

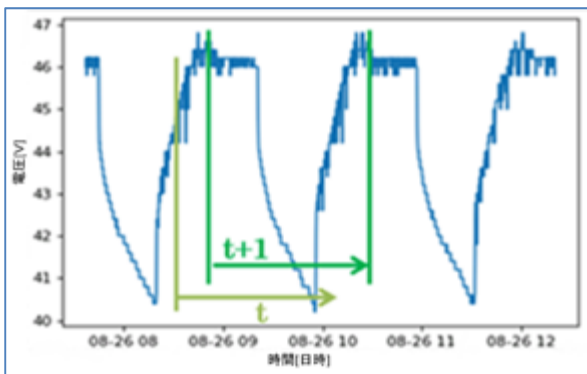


図 4. バッテリー電圧の周期




図 5. kNN 異常判定

バッテリーの電圧は衛星の軌道周期と同様の周期があり、約96分で1周期となる。横軸を時間、縦軸を電圧で表したものが図4である。この1周期を144次元(40秒刻み)のデータとして部分時系列を作成した。その部分時系列を学習し、最近傍の距離を測定すると、図5のように正常なデータは近くに密集し、異常なものは遠くに分布する。よって、最近傍までの距離を異常度とし、一定以上異常度が高いものを異常とみなす。

3.2 RNN を用いた異常検知

RNN (Recurrent Neural Networks) は、時系列データの扱いに特化した NN (Neural Network) の

一種である。NN は人間の脳の構造を模した機械学習のアルゴリズムであり、RNN は過去の隠れ層を取り入れることにより時系列データの予測を可能としている。RNN の構造を図 6 に示す。

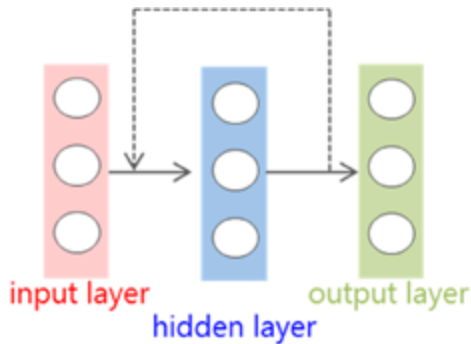


図 6. RNN モデル

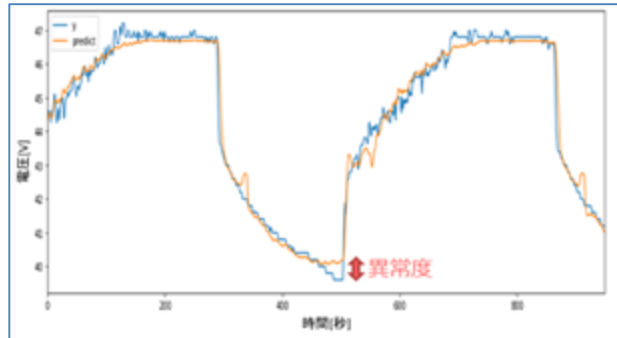


図 7. RNN 実際の値 (青) と予測値 (橙)

シーケンス長を 30、隠れ層のノード数を 400 とし、直近の部分時系列を用いて現在値を予測するように学習し、実際の値と予測した値を比較する。正常時のデータを学習したモデルでは、異常時のデータを予測できないため、予測値と実際の値の差が大きいほど異常であると考えられることができる。よって、図 7 のように予測結果と実際の値の差 (2 乗誤差) を異常度とし、異常を検出する。

3.3 AutoEncoder を用いた異常検知

AutoEncoder (自己符号化器) は、NN を用いて特徴表現を獲得する機械学習の手法である。入力層と出力層に同じデータを用いることで、ニューロン数を削減した中間層にデータの特徴を獲得することができる。AutoEncoder の構造を図 8 に示す。




図 8. AutoEncoder モデル




図 9. AutoEncoder 実際の値 (青) と再構成 (橙)

バッテリーの電圧と温度の計 4 次元のデータを入力し、項目間の関係を学習する。入力した学習データを出力層でそのまま再現するように学習した NN は、学習データと傾向が異なる異常時のデータを正しく再構成することができない。図 9 のように実際の値と再構成した結果の差（2 乗誤差）の合計を異常度とし、異常を検出する。

3.4 OneClassSVM を用いた異常検知

SVM（サポートベクターマシン）は、マージン最大化という手法を用いてデータを 2 クラスに分類する教師あり学習の手法である。OneClassSVM は、SVM と同様の手法を用い、データを 1 クラスに分類することで外れ値を検出する教師なし学習の手法である。データのまわりに境界をつくりデータがそのクラスに属するかを判定し、それ以外は外れ値とみなす。




図 10. 周期の開始をあわせたバッテリー電圧

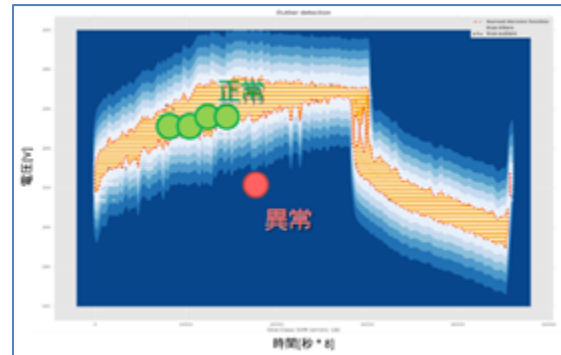


図 11. OneClassSVM 異常判定

図 10 のように、バッテリー電圧値の周期の開始タイミングを統一し、各タイミングの項目の値を学習させる。学習した結果、生成される境界を図 11 に示す。正常の場合は境界内にプロットされ、異常の場合は境界外の離れた位置に存在することになる。境界からの距離を異常度とし、異常を検出する。OneClassSVM での学習には RBF カーネルを用いた。

4. 異常検知結果・考察

4.1 異常検知結果

3 章で説明した 4 つの手法を用いて異常を検出した結果を図 12, 図 13, 図 14, 図 15 に示す。

正常状態と異常状態を区別するために閾値が必要であるが、訓練データが月毎に異なるため一定値を基準とすることはできない。そのため、訓練データに関して異常度を算出し、その異常度の標準偏差に一定値を掛け合わせた値を各月の閾値として算出した。閾値に掛け合わせる一定値は、安定期に誤報が起らないよう手法毎に調整している。図の縦軸は異常率（学習データの異常度/訓練データから算出した閾値）とし、「1」を超えたもの（閾値を超えたもの）を異常とみなす。




図 12. kNN 異常率 (赤線：閾値, 橙線：対象の SAFEHOLD)

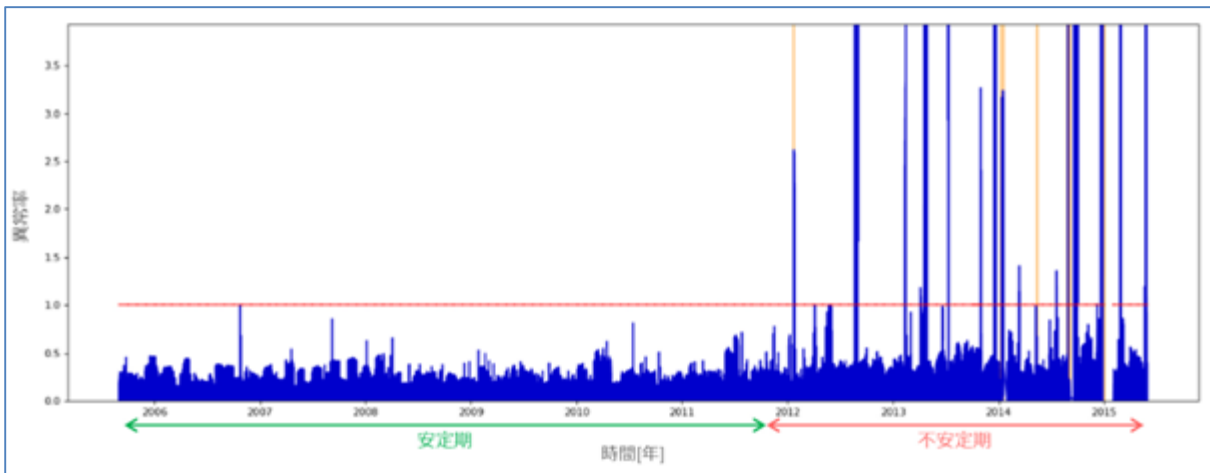


図 13. RNN 異常率 (赤線：閾値, 橙線：対象の SAFEHOLD)

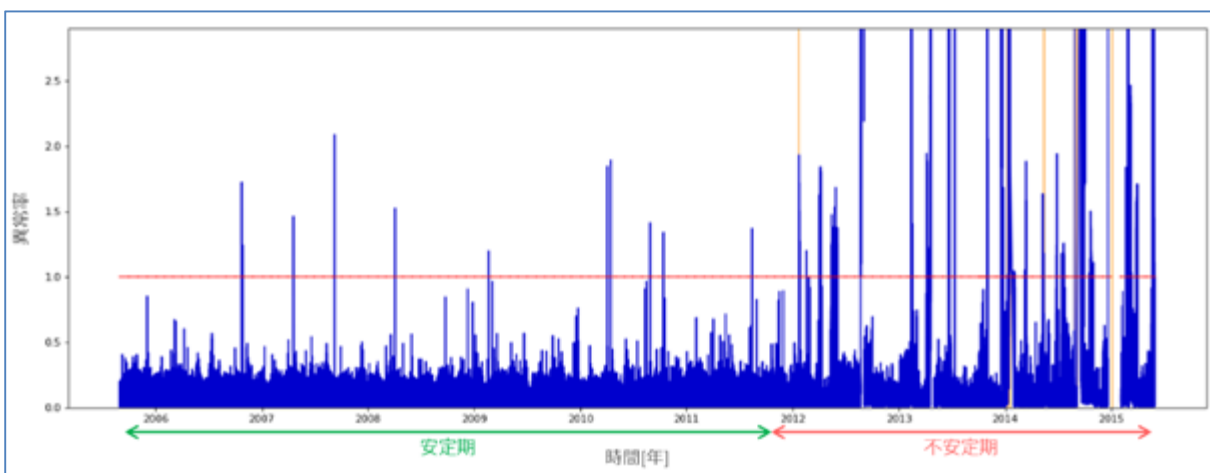


図 14. AutoEncoder 異常率 (赤線：閾値, 橙線：対象の SAFEHOLD)

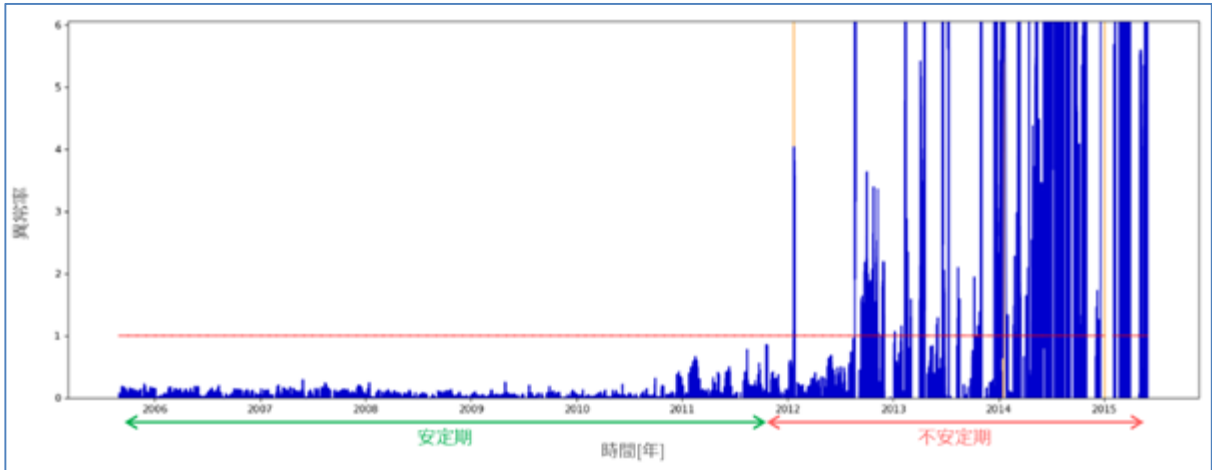


図 15. OneClassSVM 異常率 (赤線：閾値，橙線：対象の SAFEHOLD)

4.2 考察

各手法での検出可能時間 (SAFEHOLD をどれくらい前に検出することができたか，SAFEHOLD 前に異常度が閾値を超えた時間) を表 3 に示す。2 章で述べたとおり，不安定期は，バッテリーの状態が不安定になり，モード変更も行われていたことから，異常度も高く検出されている。ここでは，安定期の誤報発生状況と不安定期初回の SAFEHOLD の検出結果に焦点を当て，学習時間および異常度算出時間を含めて考察を行った。

表 3. 各手法での故障の予兆検知まとめ

	SAFEHOLD 検出可能時間 (時間前)							SAFE HOLD 検出数	安定 期誤 報数	学習時間 (月あたり)	異常度 算出時間 (月あたり)
	1	2	3	4	5	6	7				
kNN	13	42	115	×	×	×	328	4/7	0	○ (1分未満)	△ (10分未満)
RNN	28	×	110	×	×	×	327	3/7	0	△ (約30分)	○ (数秒)
AutoEncoder	12	21	117	×	×	×	328	4/7	11	△ (約10分)	○ (数秒)
OneClassSVM	44	108	117	126	×	140	328	6/7	0	○ (数秒)	○ (数秒)

表 4. kNN の閾値と誤報の関係

	SAFEHOLD 検出可能時間 (時間前)							SAFEHOLD 検出数	安定期 誤報数
	1	2	3	4	5	6	7		
kNN	13	42	115	×	×	×	328	4/7	0
	25	53	115	×	×	×	328	4/7	3
	36	75	115	125	×	×	328	5/7	76

各手法において不安定期の初回の SAFEHOLD を 12 時間以上前から検出可能であることを確認した。特に、RNN と OneClassSVM は安定期の誤報がなく、1 日以上前から検出することが可能である。閾値の調整次第では、誤報も増えるが、検出可能時間を長くすることが可能である。安定期の誤報を許容するのであれば、kNN も 1 日以上前から故障の予兆を検出することが可能である。例えば、表 4 のように 3 件の誤報を許容するのであれば、kNN も 1 日以上前から故障の予兆を検出することが可能である。

以上のことから、実際の宇宙機の運用においても、電源関連の値から算出された異常度やその傾向から故障が発生しそうであるという予兆を検出することが可能である。運用要件にあわせて閾値を調整することで、より早く故障の予兆を検出することもできる。

今回の結果では、すぎく衛星に対しては、安定期の誤報が少なく、より早期から多くの SAFEHOLD を検出することができ、かつ学習及び異常度算出にかかる時間も比較的短い OneClassSVM が一番有用な手法であるといえる。このような結果となった要因の 1 つとして、kNN や RNN, AutoEncoder はクラスタリングや予測値の推定に使用される手法であり、それらを応用して異常検知に用いたのに対し、OneClassSVM は外れ値を検出することを目的とした手法であり、今回の異常検知問題に関しても、その手法の特性が有効に働いたことが考えられる。

5. まとめ

機械学習技術を用いて、運用データから故障を事前に検知するためのモデル構築を行った。様々なアルゴリズムを検証した結果、初回の故障の予兆検出に着目すると kNN, RNN, AutoEncoder, OneClassSVM の 4 つのモデルで良好な結果が得られた。また、安定期の誤報数や検出可能時間から OneClassSVM が 4 手法の中でも一番良い結果が得られた。安定期フェーズでの誤報を限りなく抑えつつ、不安定期フェーズの中でも比較的安定した期間の最初の異常を 1 日以上前から検出ことが可能であり、実運用上有用であると考えられる。

今後は他の衛星へも同様の手法を適用できるか確認し、現在運用中の宇宙機や将来打ち上がる宇宙機へ適用できるかを検討する。また運用で使用するためには、運用担当者にとって宇宙機の状況が分かりやすいことも重要であるため、異常度が高くなると警告が発生するようなシステムのプロトタイプを作成し、宇宙機の運用に貢献することを目標とする。

参考文献

- [1] C-SODA at ISAS/ JAXA, “DARTS,” [オンライン]. Available: <http://www.darts.isas.jaxa.jp>. [アクセス日: 21 8 2018].
- [2] JAXA 宇宙科学研究本部 高エネルギー天文学研究系, “すぎくホームページ,” [オンライン]. Available: <http://www.astro.isas.jaxa.jp/suzaku/>. [アクセス日: 29 8 2018].
- [3] 常田佐久, *X線天文衛星「すぎく」の科学的成果について*, 2015.
- [4] 前田良知, “バテてもめげない BAT サッパリわからん SAP,” *天文月報*, pp. 14-20, 1 2016.
- [5] 井手剛, 入門 機械学習による異常検知—Rによる実践ガイド, コロナ社, 2015.
- [6] 井手剛, 杉山将, 異常検知と変化検知, 講談社, 2015.
- [7] 巢籠悠輔, 詳解 ディープラーニング ~TensorFlow・Kerasによる時系列データ処理~, マイナビ出版, 2017.
- [8] 乾稔, 矢入健久, 河原吉伸, 町田和雄, “次元削減の再構成誤差を用いた異常検知手法の比較,” 2009.
- [9] 矢入健久, 乾稔, 河原吉伸, 高田昇, “次元削減とクラスタリングによる宇宙機テレメトリ監視法,” 2011.
- [10] 櫻田麻由, 矢入健久, “オートエンコーダを用いた次元削減による宇宙機の異常検知,” 2014.