応
般

# 衛星の状態監視システムのつくりかた —過去のデータに基づく異常検知—

矢入健久（東京大学大学院工学系研究科）

## 研究の経緯

筆者が人工衛星のためのデータ駆動型異常検知の研究を始めたのは，かれこれ今から十数年ほど前である．学生時代の恩師であるN先生を通じて知り合ったJAXA（宇宙航空研究開発機構，当時は宇宙開発事業団）のF氏とI氏が，「人工衛星のデータをマイニングしたら面白いことができるのでは？」と言って訪ねて来たのがきっかけであった．当時はまだ機械学習やデータマイニングという言葉すら一部の研究者以外には知られていなかった時代である．お2人には先見の明があったといえよう．かくして，すでに運用を終えていた実験衛星を対象として，地上局に保存されていたハウスキーピングデータ（衛星システムを構成するさまざまなセンサ計測値や，機器のステータスなどを集めたデータ）に対していろいろな機械学習アルゴリズムを適用することから始めた．しかし，我々の「データを中心とした」異常検知への試みに対する当初の宇宙業界の反応は，概して冷やかであった．旧知の衛星技術者には，「過去の衛星データを掘り返したところで何も出てきやしませんよ．重要な知識は我々技術者の頭や設計書の中にあるのです」と言い放たれたのであった．

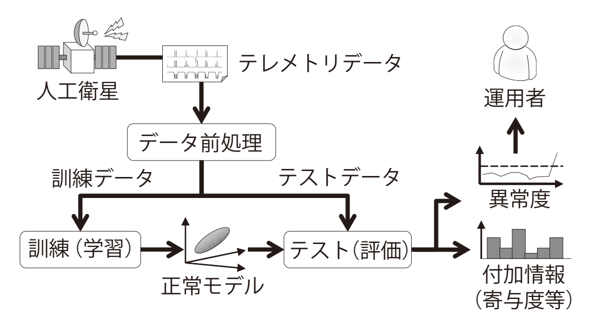

図-1　データ駆動型異常検知の基本プロセス

それから時が過ぎ，いつしか「ビッグデータ」の時代が到来していた．正直なところ，「データがあれば何でもできるに違いない」という世間からの過度な期待には違和感を覚えるが，技術的基盤の面においても，機械学習・データマイニングの分野でも異常検知というジャンルが確立しており，また，我々もJAXAや大学，民間企業との共同研究を積み重ねてきたことにより，人工衛星のためのデータ駆動型異常検知・健康状態監視法の実用化まであと一歩という段階に達している．

## データ駆動異常検知の考え方

基本的なデータ駆動型（学習型）異常検知は，大きく2つのフェーズから構成される（**図-1**）．まず，訓練フェーズでは，過去の正常データからシステムの正常な挙動を表す統計的モデルを学習する．そして，テストフェーズでは，学習したモデルを用いて新しいデータを評価し，著しく外れていれば異常と判定する．この問題は，機械学習では1クラス分類として知られている．

このように一般的な異常検知の枠組み自体は非常に単純であるが，実際に対象システムの正常挙動をどのようにモデル化するかという点で大きなバリエーションが生じる．たとえば，単純なものとしては，多変量のセンサ値の分布を多次元ガウス分布や線型部分空間によって近似的にモデル化することが考えられる．また，従来のリミットチェックも各変量ごとに上限値と下限値によってモデル化していると解釈できよう．一方，複雑なものとしては，条件分岐

を扱うような木モデル，確率的グラフモデル，混合分布モデル，非線形部分空間など，枚挙にいとまがない．そうなると，当然，「どのモデルを使うのが1番良いのか？」という疑問が生じるが，それを論じるには，まず，監視対象となる衛星データの特徴を考察する必要がある．

## 人工衛星テレメトリの特徴

一般的に，人工衛星のテレメトリに共通する性質として以下の6点が挙げられる．

（1）**超高次元性**：現在の衛星のテレメトリは数百から数千もの変量から構成される．その中には互いに強い相関を持つものも含まれる．

（2）**多モード性**：人工衛星にはさまざまな動作モードがあり，データの分布にもそれを反映したクラスタ構造が見られる．

（3）**異種性**：テレメトリを構成する変量群には大きく，アナログ値をとる連続変量と離散値をとるステータス変量の2種類があり，さらに連続変量には，物理単位や値域の異なるさまざまな変量が含まれる．

（4）**時系列性**：テレメトリは各時刻の値が互いに独立ではなく，近接時刻の値に依存する時系列データである．

（5）**非ガウス性ノイズ**：通常のガウス的なノイズ以外に，計測時や通信時のエラーによる値の「化け」が頻繁に見られる．

（6）**構造的欠損**：センサによって計測頻度が異なったり，通信容量の制約から意図的に計測を省くことがあり，結果としてデータに構造的な欠損が生じる．

これらの性格をすべて扱えるモデル化・学習手法を考えることは難しい．実際には，値域の正規化や外れ値除去，欠損補間などのデータ前処理を行った上で，いくつかの性格を選択的に重視するモデル化方法を用いるのが現実的である．筆者らは現在，特に（1），（2）および一部（3）の性質に着目し，次元削減とクラスタリングを組み合わせた手法（混合確率主成分分析を拡張する手法）を用いている．なお，手前味噌ではあるが，クラスタリングや線形・非線形次元削減などさまざまな手法を実験的に比較した研究を行っている[1)]ので，ご興味があれば参考にされたい．

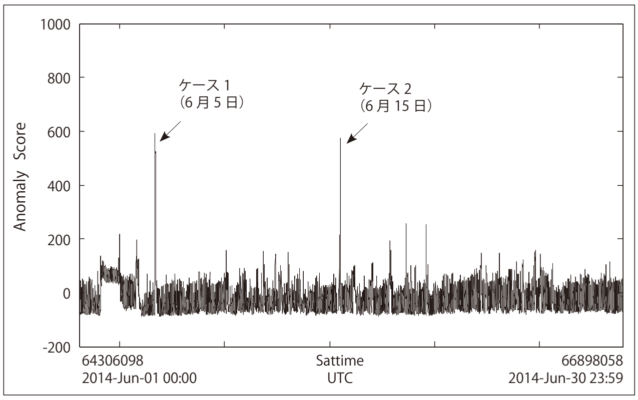


図-2 2014年6月のSDS-4テレメトリの異常度

## SDS-4運用での検証事例

筆者らは現在，JAXA研究開発本部（現：研究開発部門）の小型実証衛星4型（SDS-4）プロジェクトチームと共同で，データ駆動型異常検知システムの検証実験を行っている．ここでは，2013年1月から現在まで約2年半分のデータについて，過去3カ月分を訓練データとしてモデルの学習を行い，その後の1カ月分を評価するという訓練―テストサイクルを採用している．また，SDS-4には元々約1,400個のテレメトリ変量があるが，（1）ほとんどの時刻で値を取得していないもの，（2）不可視時には取得しないもの，（3）取得間隔が非常に長いもの，（4）衛星の位置座標など，衛星システムの健康状態とは直接関係のないもの，なども多く含まれているため，それらをとり除いて，連続変量89個，ステータス変量356個を監視対象とした．

これまでの実験ですでにさまざまな興味深い事例が見つかっているが，紙面の都合上，ここでは典型的な事例を紹介するにとどめる．**図-2**は，2014年3月1日から5月末日までの3カ月分の訓練データから学習されたモデルを用いて2014年6月の1カ月分のデータを評価したときの異常度の変遷を示し

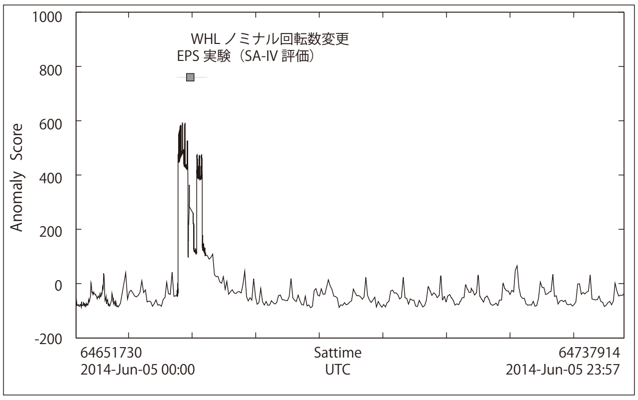


図 -3　2014 年 6 月 5 日（ケース 1）の異常度

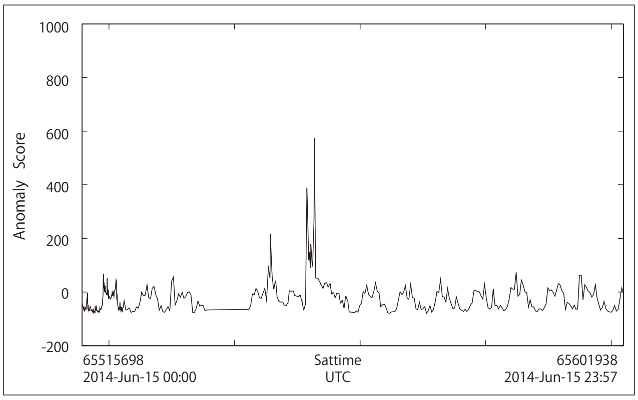


図 -4　2014 年 6 月 15 日（ケース 2）の異常度

たものである．この図を見て明らかなように，6 月 5 日と 6 月 15 日の 2 回に渡って異常度が大きく上昇している．ここでは，便宜上，前者の事象をケース 1，後者の事象をケース 2 と呼ぶことにする．

まず，ケース 1 を含む 6 月 5 日の異常度を拡大して表示したものが**図 -3** である．ここで，異常度のグラフの上にある「WHL[☆1] ノミナル回転数変更」や「EPS[☆2] 実験（SA-IV 評価）」という表示は，当該時刻に実施されていた運用イベント名を記したものである．つまり，これらの運用を実施していた時間帯に異常度が大きく上昇していることが分かる．実は，この日は，太陽電池の電流—電圧特性を評価する実験（SA-IV 評価実験）が打ち上げ後初めて実施されており，異常度上昇はこのきわめて稀な運用を反映したものであると確認された．もちろん，この実験自体は正常な運用であるが，過去に前例のないシステムの挙動パターンを「異常」として検出したのは，学習型異常検知法としてきわめて合理的であるといえる．

一方，ケース 2 の異常度上昇（**図 -4**）が検出された 6 月 15 日には，実験などの運用イベントは記録されていない．運用者が事後解析したところ，「根本的な原因は不明であるが，何らかの理由によって衛星姿勢角の推定誤差が増大したために，自動的に通常とは異なる姿勢モードに遷移する」という異常な挙動パターンが確認された．つまり，運用者が事前に想定していなかった事象を検知した事例といえる．

☆1　リアクションホイールの略称
☆2　電源系の略称

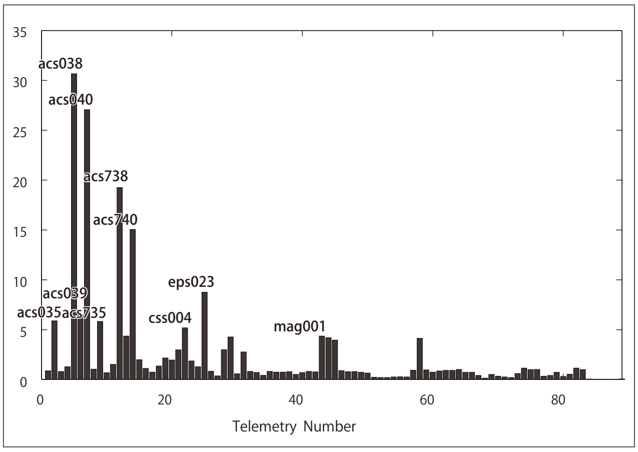


図 -5　ケース 2 における連続変量の異常度寄与度

なお，この異常検知法では，異常度に対して各テレメトリ変量がどの程度寄与しているかを計算することができる．たとえば，**図 -5** は，ケース 2 における各変量の寄与度を示したものであり，上位 10 個についてはテレメトリ ID を表示している．これから，acs038, acs040, acs738, acs740 などの寄与度が大きいことが分かるが，これらはいずれも姿勢レート（角速度）に関連する変量であることから，姿勢に関連する異常であることが推定される．

## 運用者の「代替」か「支援」か？

筆者がこれまで異常検知法を研究してきた最大の目的は，異常検知システムによって人工衛星運用者の負荷を軽減し，監視作業を代替するということであった．しかし，今回 SDS-4 運用での実証実験を行っているうちに，異常検知研究のもう 1 つの

ゴールは，運用者自身による人工衛星の健康状態の理解を促進し支援することであると考えるようになった．

その 1 つの理由は，「過去に前例のないパターンは異常とみなす」データ駆動型異常検知の宿命ともいえるが，稀な正常パターンを異常として誤判定してしまう事例が多く見られたことである．このような場合，運用者による経験と専門知識による最終判断が必要となる．つまり，やや後ろ向きではあるが，学習型異常検知システムが運用者を完全に代替するのは現状では難しいといわざるを得ない．

一方で，今回の実験では，データ駆動型状態監視器が検出した「異常」パターンを運用者が詳細に解析することによって，新たな知見を得るという事例も数多く見られた．たとえば，2013 年および 2014 年の春分，秋分の時期に異常度がやや高くなるという現象が見られたため，運用者が元データを解析したところ，これらの時期では姿勢角計測値を表現するクォータニオンの符号が頻繁に反転していることが分かった．このこと自体はシステムの異常ではないが，将来的に姿勢制御ロジック等の変更を行う際には不具合の遠因になり得る事象であり，運用者にとっては有用な情報といえる．

このように，データ駆動型異常検出システムには，運用者が普段は意識していない微妙なデータの変調を捉えることによって運用者に「気づき」を与える可能性がある．これらから，データ駆動型異常検出システムは，運用者の代替としてだけでなく，支援ツールとしても価値があると考えている．

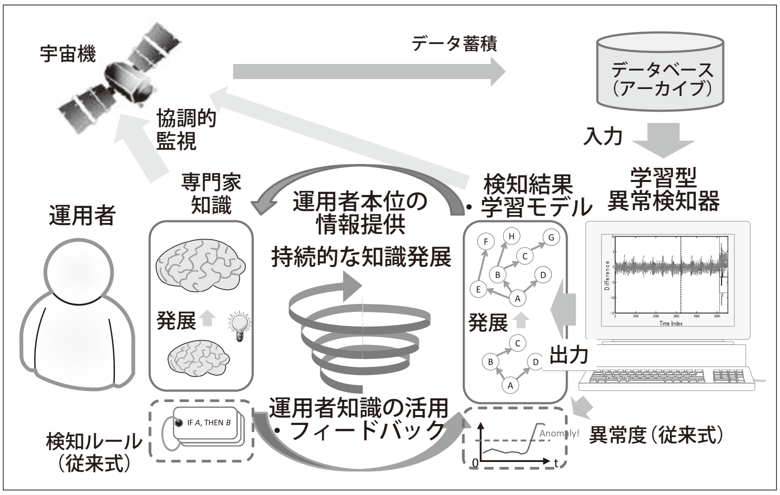

図 -6　運用者と学習型異常検知器との協調的衛星システム状態監視

## データ駆動型から協調型へ

現在，我々は前章で述べた考えに基づき，データ駆動型異常監視器を，運用者との協調型状態監視器へと発展させる取り組み（**図 -6**）を進めている．この協調型監視の主な特徴は以下の 3 点である．（1）単に異常度を出力するだけでなく，運用者が衛星状態を理解するために有用な付加情報も提供する．（2）専門家の事前知識や検出結果に対する運用者のフィードバックを取り込むことにより，監視性能を向上させる．（3）運用者と状態監視システムとが持続的にかかわり合い，衛星監視に関する互いの知識を相乗的に高める．この新たな試みについても，成果が出次第紹介したいと考えている．

最後に，筆者は本研究を商用衛星や大学小型衛星などさまざまな宇宙ミッションに適用して発展させていきたいと考えており，関係者の方々にはぜひともご協力を願いたい．

**参考文献**

1）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，日本航空宇宙学会論文集 , Vol.59, No.691, pp.197–205 (2011).

（2015 年 5 月 15 日受付）

**矢入健久** ■ yairi@ailab.t.u-tokyo.ac.jp

1999 年東京大学大学院工学系研究科博士課程修了．同大学先端科学技術研究センター助手，講師等を経て，現在は同大学大学院工学系研究科航空宇宙工学専攻准教授．専門は機械学習・確率推論およびそれらの航空宇宙分野への応用．

謝辞　　本稿で示した SDS-4 データへの適用例は JAXA 宇宙実証研究共同センターとの共同研究の一部であり，中島佑太氏，西村尚樹氏に多大なご協力をいただいた．また，紹介した研究の一部は JSPS 科研費 26289320 の助成を受けて実施されたものである．