

修 士 論 文

機械学習による衛星データを用いた異常検知の手法の提案  
Proposal of A Method for Anomaly Detection using Satellite  
Data Based on Machine Learning

令和 4 年度（2022 年度）

指導教員 佐原 宏典

21863634

YANG XINYU

東京都立大学大学院  
システムデザイン研究科 博士前期課程  
航空宇宙システム工学域  
佐原研究室

提出日：2023 年 1 月 27 日



## 目次

|     |                      |    |
|-----|----------------------|----|
| 1   | 序論                   | 1  |
| 1.1 | 背景                   | 1  |
| 1.2 | 課題                   | 1  |
| 1.3 | 本研究の目的               | 2  |
| 2   | 人工衛星における機械学習を用いた異常検知 | 3  |
| 2.1 | 異常の種類                | 3  |
| 2.2 | 機械学習の種類              | 3  |
| 2.3 | 従来の機械学習を用いた異常検知手法    | 5  |
| 3   | 発電量の推定方法と異常検知        | 7  |
| 3.1 | 概要                   | 7  |
| 3.2 | 対象データ                | 7  |
| 3.3 | 機械学習モデルの選択           | 9  |
| 3.4 | リミットチェックを用いた異常検知     | 11 |
| 4   | 実データへの適用             | 13 |
| 4.1 | 概要                   | 13 |
| 4.2 | 適用結果                 | 13 |
| 5   | 考察                   | 26 |
| 5.1 | 推定精度の考察              | 26 |
| 5.2 | 異常検知結果の考察            | 28 |
| 6   | 結論                   | 41 |
| 6.1 | 結論                   | 41 |
| 6.2 | 今後の課題                | 41 |
|     | Acknowledgement      | 42 |
|     | References           | 43 |

## 図目次

|      |  |    |
|------|--|----|
| 2.1  | 典型的な異常パターン . . . . .                                   | 3  |
| 3.1  | ランダムフォレストの例 . . . . .                                  | 10 |
| 3.2  | リミットチェックを用いた異常検知の流れ . . . . .                          | 12 |
| 4.1  | 正解率の定義 . . . . .                                       | 13 |
| 4.2  | 衛星と太陽の角度による特徴量を追加したモデルの流れ . . . . .                    | 14 |
| 4.3  | 2009 年 9 月の SUN_ALT と DIST_PCU_IN_I の分布 . . . . .      | 15 |
| 4.4  | 2010 年 6 月の SUN_ALT と DIST_PCU_IN_I の分布 . . . . .      | 16 |
| 4.5  | 2014 年 9 月の SUN_ALT と DIST_PCU_IN_I の分布 . . . . .      | 16 |
| 4.6  | 2009 年 9 月の分布 (SUN_ALT は 0~1) . . . . .                | 17 |
| 4.7  | 2010 年 6 月の分布 (SUN_ALT は 0~1) . . . . .                | 18 |
| 4.8  | 2014 年 9 月の分布 (SUN_ALT は 0~1) . . . . .                | 18 |
| 4.9  | 2009 年 9 月の単調増加の SUN_ALT と DIST_PCU_IN_I の分布 . . . . . | 19 |
| 4.10 | 2009 年 9 月の単調減少の SUN_ALT と DIST_PCU_IN_I の分布 . . . . . | 19 |
| 4.11 | 2010 年 6 月の単調増加の SUN_ALT と DIST_PCU_IN_I の分布 . . . . . | 20 |
| 4.12 | 2010 年 6 月の単調減少の SUN_ALT と DIST_PCU_IN_I の分布 . . . . . | 20 |
| 4.13 | 2014 年 9 月の単調増加の SUN_ALT と DIST_PCU_IN_I の分布 . . . . . | 21 |
| 4.14 | 2014 年 9 月の単調減少の SUN_ALT と DIST_PCU_IN_I の分布 . . . . . | 21 |
| 4.15 | K-分割交差検証 . . . . .                                     | 22 |
| 4.16 | K-分割交差検証を追加したモデルの流れ . . . . .                          | 23 |
| 4.17 | パラメータ最適化を追加したモデルの流れ . . . . .                          | 24 |
| 5.1  | 衛星と太陽の角度による特徴量を追加したモデルの特徴量の重要性 . . . . .               | 26 |
| 5.2  | K-分割交差検証を追加したモデルの特徴量の重要性 . . . . .                     | 27 |
| 5.3  | パラメータ最適化を追加したモデルの特徴量の重要性 . . . . .                     | 27 |
| 5.4  | 2009 年 9 月のデータに基づくモデルの推定精度の変化 . . . . .                | 28 |
| 5.5  | 2010 年 6 月のデータに基づくモデルの推定精度の変化 . . . . .                | 28 |
| 5.6  | 混同行列の定義 . . . . .                                      | 29 |
| 5.7  | 2009 年 9 月のデータの分布 . . . . .                            | 31 |
| 5.8  | 2010 年 6 月の異常データの分布 . . . . .                          | 31 |

|      |  |    |
|------|--|----|
| 5.9  | 2011 年 6 月の異常データの分布 . . . . .                | 32 |
| 5.10 | 2011 年 8 月の異常データの分布 . . . . .                | 32 |
| 5.11 | 2012 年 7 月の異常データの分布 . . . . .                | 32 |
| 5.12 | 2014 年 4 月の異常データの分布 . . . . .                | 33 |
| 5.13 | 2014 年 7 月の異常データの分布 . . . . .                | 33 |
| 5.14 | 2014 年 9 月の異常データの分布 . . . . .                | 33 |
| 5.15 | 2010 年 6 月のデータの分布 . . . . .                  | 36 |
| 5.16 | 2009 年 9 月の異常データの分布 (2 倍 RMSE) . . . . .     | 36 |
| 5.17 | 2011 年 6 月の異常データの分布 (2 倍 RMSE) . . . . .     | 36 |
| 5.18 | 2011 年 8 月の異常データの分布 (2 倍 RMSE) . . . . .     | 37 |
| 5.19 | 2012 年 7 月の異常データの分布 (2 倍 RMSE) . . . . .     | 37 |
| 5.20 | 2014 年 4 月の異常データの分布 (2 倍 RMSE) . . . . .     | 37 |
| 5.21 | 2014 年 7 月の異常データの分布 (2 倍 RMSE) . . . . .     | 38 |
| 5.22 | 2014 年 9 月の異常データの分布 (2 倍 RMSE) . . . . .     | 38 |
| 5.23 | 2009 年 9 月の異常データの分布 (平均値から分散の 2 倍を引いた) . . . | 38 |
| 5.24 | 2011 年 6 月の異常データの分布 (平均値から分散の 2 倍を引いた) . . . | 39 |
| 5.25 | 2011 年 8 月の異常データの分布 (平均値から分散の 2 倍を引いた) . . . | 39 |
| 5.26 | 2012 年 7 月の異常データの分布 (平均値から分散の 2 倍を引いた) . . . | 39 |
| 5.27 | 2014 年 4 月の異常データの分布 (平均値から分散の 2 倍を引いた) . . . | 40 |
| 5.28 | 2014 年 7 月の異常データの分布 (平均値から分散の 2 倍を引いた) . . . | 40 |
| 5.29 | 2014 年 9 月の異常データの分布 (平均値から分散の 2 倍を引いた) . . . | 40 |

## 表目次

|     |  |    |
|-----|--|----|
| 3.1 | X 線天文衛星「すざく」基本情報 . . . . .             | 7  |
| 3.2 | 使用するデータ一覧 . . . . .                    | 8  |
| 3.3 | 対象となる期間一覧 . . . . .                    | 9  |
| 3.4 | 対象となる期間一覧 . . . . .                    | 10 |
| 4.1 | ランダムフォレスト回帰モデルの結果 . . . . .            | 14 |
| 4.2 | 衛星と太陽の角度による特徴量を追加した結果 . . . . .        | 22 |
| 4.3 | K-分割交差検証を追加した結果 . . . . .              | 23 |
| 4.4 | 30 回のシミュレーション結果 . . . . .              | 24 |
| 4.5 | パラメータ最適化を追加した結果 . . . . .              | 25 |
| 5.1 | 異常検知の精度評価結果 . . . . .                  | 30 |
| 5.2 | 平均値から分散の 2 倍を引いた閾値の結果 . . . . .        | 34 |
| 5.3 | 運用期間による 2 倍 RMSE の閾値の結果 . . . . .      | 35 |
| 5.4 | 運用期間による平均値から分散の 2 倍を引いた閾値の結果 . . . . . | 35 |



## 摘要

人工衛星などの宇宙機システムは、一般にその開発には1基あたり数百億円が必要である。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く、また運用中に深刻な状態に陥ることもあり得るため、衛星の信頼性を事前の想定通りに保証することが厳しい。そのため、軌道上での異常検知と故障診断が不可欠である。

従来の宇宙機システムの異常検知手法は、機械学習により、構築されたモデルに基づく異常検知を行うものであった。機械学習に関するデータの基本的な前提には、統計的規則性の属性が必要である。そのため、データ収集の利便性などにより、一例として宇宙機システムの太陽電池やバッテリーといった電源系に関するデータを解析して異常検知を実現することがある。しかし、その計測の中断や衛星の状態遷移などのタイミングが発生することがあるため、一定期間データが欠落することがしばしばある。その時系列データ不足により高性能なモデルの構築が難しくなり、高精度な異常検知ができなくなるという問題点がある。そこで、データが欠落しても高性能なモデルを構築し、高精度な異常検知を実現することを着想した。

本研究では衛星データを用いた太陽電池発電量の推定モデルを構築し、これにより推定した発電量により異常検知を行った。

第1章では、宇宙機システムの異常検知の背景と、軌道上での自律的な異常検知が必要であること、及び本研究の課題と目的を述べた。

第2章では、データにおける代表的な異常や、機械学習の種類と従来の異常検知手法について示した。

第3章では、衛星データ特徴や、衛星データに応じた機械学習モデルと異常検知の方法を示した。

第4章では、第3章で提案した方法を実データへ適用し、各改善策のRMSEと異常検知正解率の結果を示した。

第5章では、適用結果の考察を行い、各改善策後のモデル推定精度から比較し、妥当性を確認する。また、異常検知結果の評価や閾値の設定方法などの考察を行った。





## 第 1 章

### 序論

#### 1.1 背景

##### 1.1.1 異常検知が必要な理由

通信衛星，地球観測衛星，科学衛星など様々な人工衛星が次々に登場し，我々の生活は画期的に変わった．例えば，GPS の登場により交通の利便性が大幅に上がり，また気象衛星の登場により高精度な天気予報ができるようになった．このような衛星は大型衛星や中型衛星が多数であり，一般にその開発には 1 基あたり数百億円が必要である．また運用中に深刻な状態に陥ることもあり得るため，衛星の信頼性を事前の想定通りに保証することが厳しい．そのため，軌道上での異常検知と故障診断が不可欠である．

##### 1.1.2 機械学習と異常検知

衛星などの宇宙機システムの大規模化・複雑化・多数化により，人間による監視は困難になりつつあり，異常を見落とす可能性や，小さな異常が致命的な故障を引き起こす危険性が増大している．そのため，近年では特に人工知能の技術である機械学習の利用が注目されている．機械学習の技術により，異常検知など特定の領域において人間より上回ったため，工業分野で利用されている [1]．この技術は宇宙機システムにも活用されている．

#### 1.2 課題

機械学習に関するデータの基本的な前提には，統計的規則性の属性が必要である．このようなデータを解析することにより，未知の新しいデータを予測できる．そのため，データ収集の利便性などにより，一例として宇宙機システムの太陽電池やバッテリーといった電源系に関するデータを解析して異常検知を実現することがある．しかし，その計測の中断や衛星の状態遷移などのタイミングが発生することがあるため，一定期間データが欠落することがしばしばある．その時系列データ不足により高性能なモデルの構築が難しくなり，高精度な異常検知ができなくなるという問題点がある．そこで，データが欠落しても高性能なモデルを構築し，高精度な異常検知を実現することを着想した．

### 1.3 本研究の目的

以上の背景から，太陽電池のデータが欠落していても太陽光発電の関連データから太陽電池のデータを推定できると考えられる可能性を着想し，本論文の目的を以下のように定める．

1. 衛星データを用いた太陽電池発電量の推定モデルを構築する．
2. 推定した発電量により異常検知を行う．

## 第 2 章

### 人工衛星における機械学習を用いた異常検知

#### 2.1 異常の種類

データにおける異常は大きく静的な異常と動的な異常に分けられ、図 2.1 のようなものがある。静的な異常は外れ値とも呼ばれる。図 2.1 左上のようにある点が他の大部分の点と異なる場合、異常と診断する。動的な異常は、時系列データのようにデータ間に順序性等の関係があり、データの振る舞いが異常の尺度になるものである。例えば、図 2.1 右上に示した異常は時間軸の順序を入れ替えると検知できなくなるため、時系列的な外れ値と呼ばれる。図 2.1 左下の異常は周波数の変化が生じる異常であり、変化点と呼ばれる。図 2.1 右下の異常は外れ値と変化点が同時に発生する異常であり、異常部位と呼ばれる [2]。

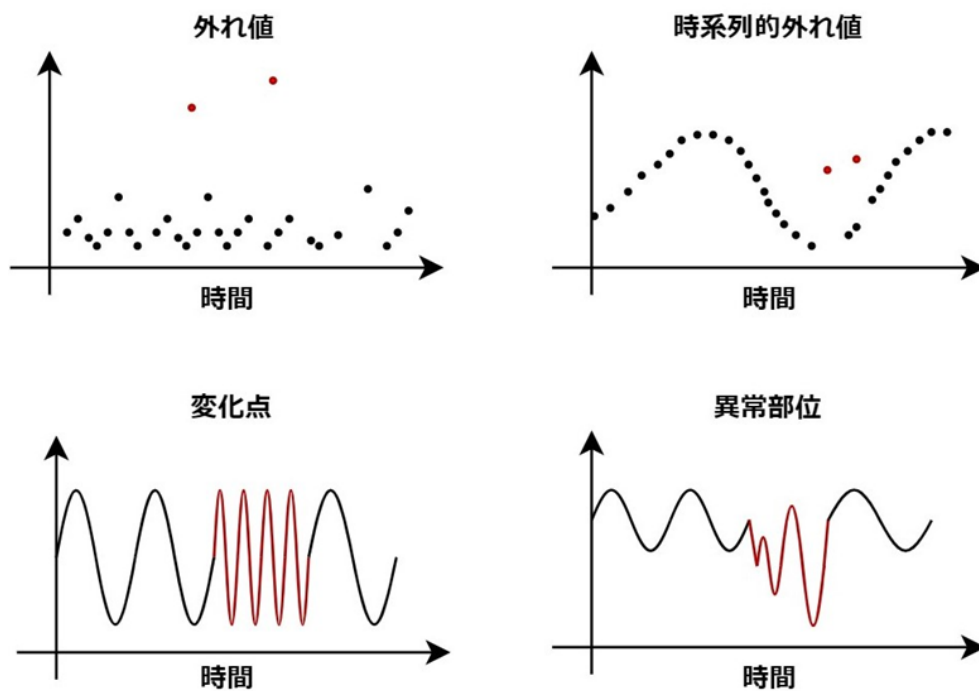


図 2.1: 典型的な異常パターン

#### 2.2 機械学習の種類

機械学習の分類には教師あり学習、教師なし学習、強化学習がある。しかし、強化学習は異常検知に使用されていないため、教師あり学習と教師なし学習を説明する。

### 2.2.1 教師あり学習

教師あり学習は事前に与えられたデータを正解データとみなして、それを元に学習を行うところからこの名がある。従来の教師あり学習には、線形回帰、ロジスティック回帰、サポートベクトルマシン、ナイーブベイズ、ランダムフォレスト、ニューラルネットワーク、kNN と呼ばれる方法が用いられている。以下にそれぞれの特徴を説明する。

線形回帰は、未知のデータの値を、関連する別の既知のデータの値を用いて予測するデータ分析手法である。未知の変数と既知の変数を一次方程式として数学的にモデル化する。

ロジスティック回帰は、数学を用いて2つのデータ要因の関係を求めるデータ分析手法である。この関係を利用して、一方の要因からもう一方の要因の値を予測する。

サポートベクトルマシンは、2クラス分類のモデルである。基本モデルは、最大の区間を持つ特徴空間上で定義される線形分類器である。

ナイーブベイズは、ベイズ定義と特徴量の条件付き独立性の仮定に基づく分類法である。推定するパラメータが少なく、欠損データに対する感度が低い。

ランダムフォレストは決定木モデルを複数利用するため、決定木単体より予測精度の向上を図る手法である。一つひとつの決定木の性能は必ずしも高くないが、それらを複数用いることにより汎化性能の高いモデルを作成できる。

ニューラルネットワークは、人間の脳にヒントを得て、コンピュータにデータ処理を教えるために用いられる人工知能の一手法である。人間の脳と同じような階層構造で相互に接続されたノードやニューロンを使用する。コンピュータが失敗から学び、継続的に改善するために使用する適応型システムを構築している。

kNN は、ノンパラメトリックな教師あり学習分類法のため、近接性を利用して個々のデータ点のグループを分類または予測する。

### 2.2.2 教師なし学習

教師なし学習は、ラベルのないデータからデータの統計的パターン、つまり本質的な構造を学習する機械学習である。従来の教師なし学習には、PCA、k-means 法、混合ガウス分布、LLE と呼ばれる方法が用いられている。以下にそれぞれの特徴を説明する。

PCA は、データを新しい座標系に変換することができる。データセットの特性を維持したまま次元を削減するためによく利用される。

k-means 法は、サンプル集合の分割に基づくクラスタリングアルゴリズムである。サンプル集合を  $k$  個のクラスを構成する  $k$  個の部分集合に分割し、 $n$  個のサンプルを  $k$  個のクラスに分類し、それぞれのサンプルが属するクラスの中心からの距離が最も小さくなるようにする。

混合ガウス分布は、 $k$  個の単一ガウスモデルの組み合わせと考えることができ、 $k$  個のサブモデルは混合モデルの隠れ変数となる。混合モデルは任意の確率分布を用いることができるが、ここでは、ガウス分布の数学的性質と計算性能の良さから、ガウス混合モデルを用いている。

LLE は、非線形信号の特徴ベクトルの次元を最適化する手法である。この次元の最適化は、単なる量的削減ではなく、元のデータの特性を変えずに、高次元空間から低次元空間への信号のマッピング、すなわち固有値の二次抽出である。

## 2.3 従来の機械学習を用いた異常検知手法

本節では、代表的な異常検知手法について説明する。従来の異常検知には、リミットチェック法、ルールベース推論、モデルベース推論と呼ばれる手法が用いられている。

### 2.3.1 リミットチェック法

リミットチェック法は、他の様々な地上システムと同様、宇宙機システムにおいて最も基本的かつ現在最も利用されている異常検知手法である。基本的な動作原理は、システムの各構成要素において観測される電流・電圧・角速度・温度などのさまざまな物理量が事前に設定された適正な上限値と下限値の間に収まっているかどうかを監視し、システムの正常・異常を判断するというものである [3]。

閾値（上限値・下限値）は宇宙機の打上前に設計者によって設定されるが、運用フェーズにおいて再設定される場合もある。また、宇宙機のモード毎にリミット値を設定する場合や、異常の深刻さの度合いに応じて複数の閾値を設定する場合もある [4]。

リミットチェック法が現在も最も利用されている理由としては、原理の単純さ故に実装・実施が容易であり検知結果が人間にとって理解しやすいこと、実際にこの手法で検知できる異常が多いことが挙げられる。一方で問題点も存在し、閾値の範囲内で生じる異常を検知できないこと、数多くの適正な閾値設定することは非常に労力を要する作業であることが挙げられる [4]。

### 2.3.2 ルールベース推論

リミットチェック法では閾値の範囲内で生じる異常を検知できないという欠点を補う方法として研究開発されたのが、ルールベース推論（エキスパートシステム）による異常検知手法である。基本的な動作原理は、設計者によって用意された異常徴候と機器故障との関係を記したルールの集合を利用して、異常検知や異常の原因を推論するというものである [3]。

ルールベース推論の診断能力はリミットチェック法を凌駕するが、起こり得る異常徴候と機器故障の関係を全て事前に記述しておく必要があるため未知の異常には対応できない、システムの開発途中で設計変更が生じた場合にルールの一貫性の維持が難しい、徴候の数が増えた場合に設計者が各ルールの信頼度を設定することが難しいという問題点が存在する [4]。

### 2.3.3 モデルベース推論

ルールベース推論と並んで研究開発されてきた方法が、モデルベース推論による異常検知手法である。基本的な動作原理は、システムのモデルを利用して計算機上でシミュレーションを行い、実際のシステムの挙動と比較することによって、異常検知や、その原因を推定するというものである [3]。

ルールベース推論と同様にモデルベース推論の診断能力はリミットチェック法を凌駕するが、正確なモデルベースを人手で構築及び維持することは非常に労力を要するという問題点が存在する [4]。

## 第 3 章

### 発電量の推定方法と異常検知

#### 3.1 概要

本論文では太陽電池発電量を推定するため，発電量に影響を及ぼす可能性があるデータセットを選択する．選択したデータセットにより，衛星データの取得方法と衛星の健康状態を紹介する．さらに，データの属性に基づいての機械学習モデルと異常検知手法を説明する．

#### 3.2 対象データ

##### 3.2.1 データ取得方法

機械学習モデルは非常に大規模なデータ量を必要とし，実際に運用中に衛星異常が発生したものをを用いることが望ましい．そこで，X 線天文衛星「すざく」(ASTRO-EII) のデータを用いることとした．すざくの HK データ (House Keeping データ) や観測データのほぼ全てが DARTS (Data Archives and Transmission System) [5] 上で公開されており，当時の運用ログを「すざく」のウェブページ [6] 上で確認することが可能である．

表 3.1: X 線天文衛星「すざく」基本情報

|       |                        |
|-------|------------------------|
| 打上日   | 2005 年 7 月 10 日        |
| 機能停止日 | 2015 年 6 月 1 日         |
| 軌道    | 高度 550km, 傾斜角 31 度の円軌道 |
| 軌道周期  | 96 分                   |



### 3.2.2 データセットとデータ期間

データセットを入力特徴量と出力特徴量に分ける．入力特徴量は出力特徴量を推定するために用いる特徴量である．発電量には熱源の強さとアレイ面を太陽方向に向ける面積が重要要素のため [7]，発電量に影響を及ぼす可能性がある入力特徴量として計 7 種類を用いる．使用するデータの一覧を表 3.2 に示す．FOC\_RA, FOC\_DEC, SAT\_ALT は衛星と地球の相対位置，EULER1, EULER2, EULER3 は衛星の姿勢，SUN\_ALT は衛星と太陽の相対角度を決めることができる．DIST\_PCU\_IN\_I は実際の発電量である．

表 3.2: 使用するデータ一覧

| 名称            | 概要  | 特徴量種類 |
|---------------|---|-------|
| FOC_RA        | RA.(J2000) of foc center pos (deg)          | 入力特徴量 |
| FOC_DEC       | DEC.(J2000) of foc center pos (deg)         | 入力特徴量 |
| SAT_ALT       | Altitude of satellite orbit from earth (km) | 入力特徴量 |
| EULER1        | Satellite euler angles phi(deg)             | 入力特徴量 |
| EULER2        | Satellite euler angles theta(deg)           | 入力特徴量 |
| EULER3        | Satellite euler angles psi(deg)             | 入力特徴量 |
| SUN_ALT       | Altitude of the sun from the earth rim(deg) | 入力特徴量 |
| DIST_PCU_IN_I | Power control unit in current(A)            | 出力特徴量 |

すざくは 2011 年 11 月以降から太陽電池の発生電力が低下し，異常が発生したことが確認されている [8]．そのため 2011 年 11 月以前のデータを正常であると判断し，本研究で適用する期間の一覧を表 3.3 に示す．

表 3.3: 対象となる期間一覧

| 番号 | 期間                                  | 正常/異常 | ミッション                |
|----|-------------------------------------|-------|----------------------|
| ①  | 2009/09/25 13:53 ~ 2009/09/28 15:26 | 正常    | SGR_B2               |
| ②  | 2010/03/06 04:03 ~ 2010/03/08 21:00 | 正常    | (L,B)=(0.107,-1.425) |
| ③  | 2011/06/22 23:12 ~ 2011/06/23 20:27 | 正常    | COMA NW6.5           |
| ④  | 2011/08/12 04:03 ~ 2011/08/16 09:17 | 正常    | SNR 0519-69.0        |
| ⑤  | 2012/07/28 06:02 ~ 2012/07/28 07:46 | 異常    | ESO 511-G030         |
| ⑥  | 2014/04/01 04:42 ~ 2014/04/03 17:23 | 異常    | SN 2014J             |
| ⑦  | 2014/07/02 03:12 ~ 2014/07/02 14:00 | 異常    | CEP X-4              |
| ⑧  | 2014/09/23 08:51 ~ 2014/09/27 06:40 | 異常    | IGR J17451-3022      |

### 3.3 機械学習モデルの選択

適用させる期間は正常期間と異常期間に分かれるため、教師あり学習を選択した。機械学習モデルの信頼性、精度と解釈性が本研究の機械学習モデル選定基準であるため、特徴量の重要度を知ることができ、質的データと量的データが混在している状態でも解析が可能という特徴があるランダムフォレスト回帰を使用した。次に、ランダムフォレスト回帰を説明する。

まず、回帰木を説明する。回帰木はそれぞれ入力特徴量から、出力を計算する回帰モデルである。 $x$  と  $y$  は入力と出力特徴量であり、式 (1) に示すようなデータセットである。

$$D = \{(x_1, y_1), (x_2, y_2), \dots, (x_N, y_N)\} \quad (1)$$

回帰木は入力空間を分割し、分割されたセル上の出力値を対応させる。入力空間が個のセルに分割され、各セルに固定出力値があると仮定すると、モデルは式 (2) で表現される。

$$f(x) = \sum_{m=1}^M c_m I(x \in R_m) \quad (2)$$

入力空間の分割が決まると、学習データに対する回帰木の予測誤差は二乗誤差で表現でき、各セルでの最適出力値は最小二乗誤差の基準で解くことができる。セルの最適値は、であることが分かる。 $\hat{c}_m$  は式 (3) に示すように、 $R_m$  上のすべての入力インスタンス  $x_i$  に対応する出力の平均値である。

$$\hat{c}_m = \text{ave}(y_i | x_i \in R_m) \quad (3)$$

次に、入力空間の分割を行う。ここではヒューリスティックを用いて、 $j$  番目の変数  $x^{(j)}$  とその値  $s$  を分割変数と分割点として選択し、式 (4) と式 (5) のように二つの領域を

定義している.

$$R_1(j, s) = \{x | x^{(j)} \leq s\} \quad (4)$$

$$R_2(j, s) = \{x | x^{(j)} > s\} \quad (5)$$

そして, 最適な分割変数  $j$  と最適な分割点  $s$  を求めるために式 (6) のように計算する.

$$\min_{(j,s)} [\min_{c_1} \sum_{x_i \in R_1(j,s)} (y_i - c_i)^2 + \min_{c_2} \sum_{x_i \in R_2(j,s)} (y_i - c_i)^2] \quad (6)$$

最適な分割点  $s$  は, 変えない分割変数  $j$  に対して求めることができる.

$$\hat{c}_1 = \text{ave}(y_i | x_i \in R_1(j, s)) \quad (7)$$

$$\hat{c}_2 = \text{ave}(y_i | x_i \in R_2(j, s)) \quad (8)$$

全ての入力特徴量を繰り返し, 最適な分割変数  $j$  を見つけ, ペアを構成する. 次に, 入力空間を二つの領域に分割し, 各領域について停止条件が満たされるまで上記の分割処理を繰り返す. こうして回帰木が生成される.

ランダムフォレスト回帰はこの操作を複数回行い, 選定されたデータからいくつかの回帰木を生成する. また, ランダムに特徴量を選定かつ複数の木を生成する. 図 3.1 [9] に示すように, 各回帰木の平均値を最終出力特徴量として出力する.

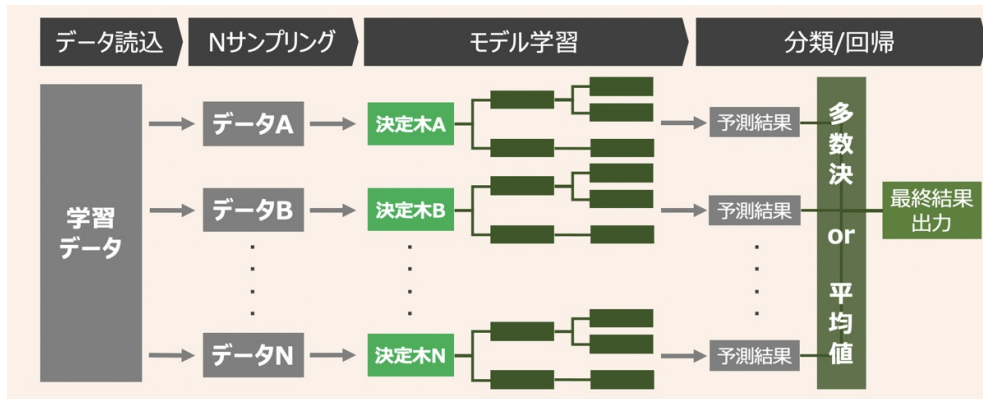


図 3.1: ランダムフォレストの例

表 3.4 は本研究で使ったランダムフォレスト回帰のハイパーパラメータを示している.

表 3.4: 対象となる期間一覧

| ハイパーパラメータ                 | 説明                                    |
|---------------------------|---------------------------------------|
| <code>n_estimators</code> | 利用する回帰木の数                             |
| <code>max_depth</code>    | <code>n_estimators</code> で指定した回帰木の深さ |

### 3.4 リミットチェックを用いた異常検知

リミットチェック法は他の様々な地上システムと同様，宇宙機システムにおいて最も基本的かつ現在も最も利用されている異常検知手法であるため，本研究の異常検知手法でも使用した．二乗平均平方根誤差（RMSE）は絶対精度として使用できるため，リミットチェックの閾値は  $RMSE \times 2$ （以降，2 倍 RMSE）と設定する．異常検知に用いられるデータの特性やアプリケーションの目的などによって異なる．今回の衛星データの規律で（正常時期の発電量と異常時期の発電量の大きさ）、2 倍ぐらゐは適切な閾値決定と考えられる．また、何倍に設定することは決めの問題のため、実際の運用上では閾値ごとに警戒レベルの一緒に設定することが望ましい。発電量の推定値と実値の RMSE を計算し，データの類似性を評価する．式 (9) は RMSE を表している．

$$RMSE = \sqrt{\frac{1}{m} \sum_{i=1}^m (\hat{y}_i - y_i)^2} \quad (9)$$

ここで， $y_i$  は実値， $\hat{y}_i$  は推定値を意味している．本研究では，正常期間のデータ分布はほぼ同じであると考え，ある正常期間の RMSE を閾値として決め，異常検知を行う．2009 年 9 月のデータを基づくモデルを構築し，2011 年 6 月に異常検知を行う例を図 3.2 に示す．

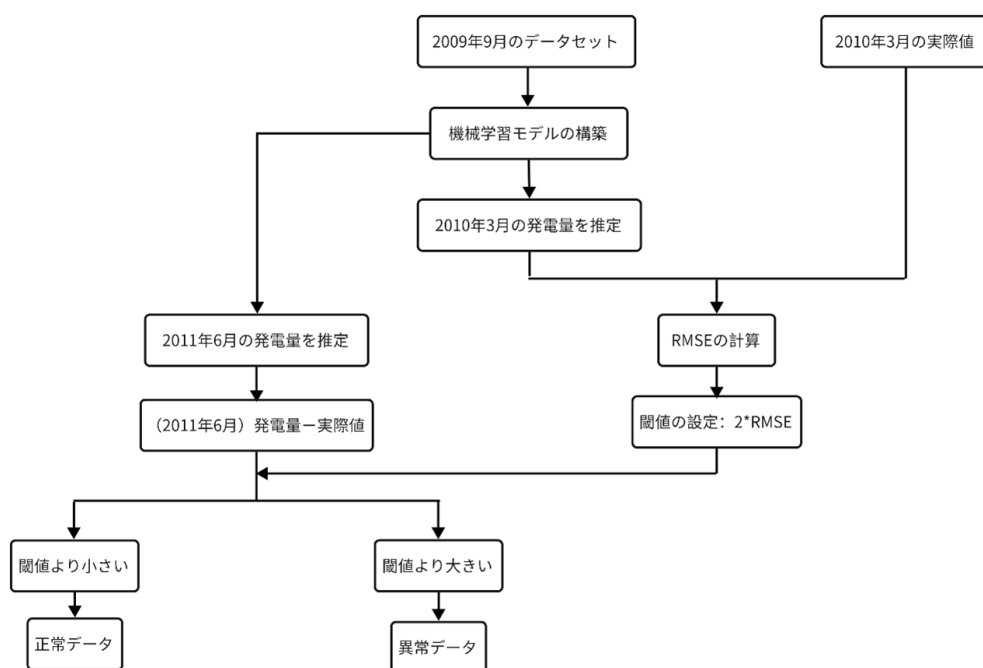


図 3.2: リミットチェックを用いた異常検知の流れ

## 第 4 章

### 実データへの適用

#### 4.1 概要

推定値と実値の RMSE を小さくするために、ランダムフォレスト回帰モデルの改善が必要である。モデルに実データを適用し、3つの改善策を追加した。そして、各改善策を追加した推定精度と異常検知の結果を示した。本章では、2009 年 9 月のデータを基づくモデルを構築した。

#### 4.2 適用結果

##### 4.2.1 ランダムフォレスト回帰

まず、ランダムフォレスト回帰モデルを構築した。結果を表 4.1 に示す。正解率の定義は図 4.1 に示す。RMSE が大きいため閾値も大きくなったことから、正常期間の正解率が非常に高い。そして、閾値が大きいと各異常期間のデータは不規則に並んでおるから、正解率は異常期間によって異なった。この結果に対しては、モデルの精度を上げ、RMSE と閾値を小さくすることが重要である。そこで、モデル精度を改善するために、衛星と太陽の角度による特徴量、K-分割交差検証、パラメータ最適化の 3 つの改善策を一つずつ追加して確認を行った。

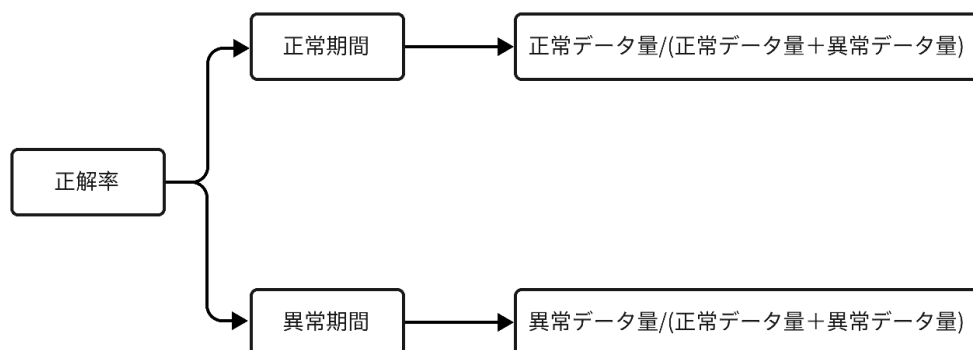


図 4.1: 正解率の定義

表 4.1: ランダムフォレスト回帰モデルの結果

| 期間      | 正常/異常 | RMSE   | 正常データ量 | 異常データ量 | 正解率    |
|---------|-------|--------|--------|--------|--------|
| 2010/06 | 正常    | 4.207  | 14578  | 35     | 99.76% |
| 2011/06 | 正常    | 4.019  | 5267   | 17     | 99.67% |
| 2011/08 | 正常    | 4.108  | 23862  | 24     | 99.90% |
| 2012/07 | 異常    | 9.234  | 409    | 683    | 62.60% |
| 2014/04 | 異常    | 8.068  | 37595  | 25479  | 40.39% |
| 2014/07 | 異常    | 9.437  | 2909   | 13475  | 82.24% |
| 2014/09 | 異常    | 11.089 | 86     | 14855  | 99.42% |

#### 4.2.2 衛星と太陽の角度による特徴量を追加した結果

モデルを改善するために、特徴量エンジニアリングを適用した。特徴量エンジニアリングは、既存の特徴量から推定して新たな特徴量を作成することである。推定の流れを図 4.2 にまとめた。

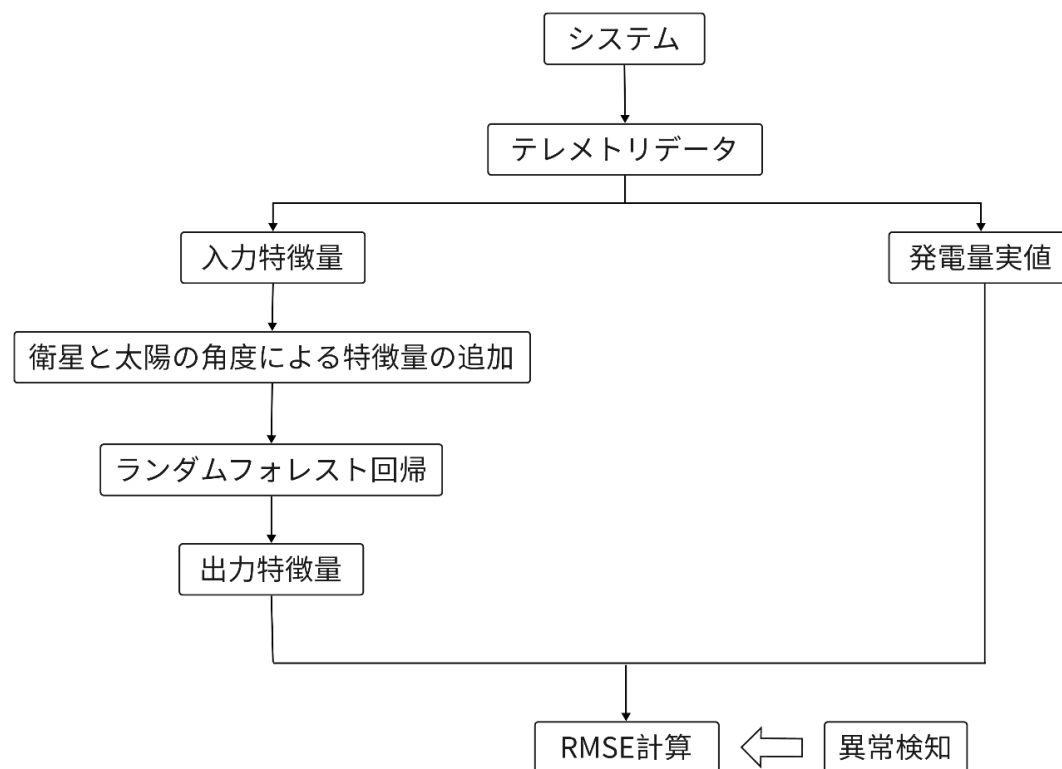


図 4.2: 衛星と太陽の角度による特徴量を追加したモデルの流れ

まず、2009 年 9 月と 2010 年 3 月のデータ分布を調べた。2009 年 9 月のデータ分布を図 4.3 に示す。2009 年 9 月のデータ分布から、SUN\_ALT と DIST\_PCU\_IN\_I の間に相関

があることが分かった。また、2010 年 3 月のデータ分布を調べた結果、図 4.4 に示すように 2009 年 9 月と同じ傾向があることが分かった。しかし、図 4.5 より、2014 年 9 月には同様の傾向は見られず、これはバッテリーが劣化した結果であると考えた。




図 4.3: 2009 年 9 月の SUN\_ALT と DIST\_PCU\_IN\_I の分布






図 4.4: 2010 年 6 月の SUN\_ALT と DIST\_PCU\_IN\_I の分布




図 4.5: 2014 年 9 月の SUN\_ALT と DIST\_PCU\_IN\_I の分布

SUN\_ALT, DIST\_PCU\_IN\_I の関係を明らかにするために、SUN\_ALT は 0～1 の範囲を設定し、2009 年 9 月、2010 年 6 月と 2014 年 9 月のデータを調べた。この理由は、SUN\_ALT が 0～1 であったとき衛星に対する太陽光の照射の開始と終了を表しており、発電量がより代表的であると考えたためである。図 4.6～4.8 に示すように、2009 年 9 月、2010 年 6 月、2014 年 9 月のデータ分布は同じ傾向を示し、DIST\_PCU\_IN\_I は 2 つの群に分けられた。しかし、2014 年 9 月の DIST\_PCU\_IN\_I は、2009 年 9 月、2010 年 6 月の DIST\_PCU\_IN\_I より低くなっている。さらに、SUN\_ALT の変化により DIST\_PCU\_IN\_I も大きい変化があると考え、SUN\_ALT の単調増加と単調減少の場合について DIST\_PCU\_IN\_I の分布を調べた。これらの結果を図 4.9～4.14 に示す。




図 4.6: 2009 年 9 月の分布 (SUN\_ALT は 0～1)




図 4.7: 2010 年 6 月の分布 (SUN\_ALT は 0~1)




図 4.8: 2014 年 9 月の分布 (SUN\_ALT は 0~1)

図 4.3, 4.9, 4.10 を組み合わせると, 2009 年 9 月るとき, SUN\_ALT の単調増加と単調減少に応じて分けた DIST\_PCU\_IN\_I は, 2009 年 9 月の DIST\_PCU\_IN\_I データ全体の分布に当てはまることが分かった. そして, DIST\_PCU\_IN\_I が単調増加のときは概ね 22 から 24 に集まった. DIST\_PCU\_IN\_I が単調減少のときは概ね 15 から 19 に集まった. また図 4.4, 4.11, 4.12 に示すように, 2010 年 6 月も同じ傾向がある. しかし, 2014 年 9 月には, 図 4.5, 4.13, 4.14 に示すように, この傾向はない.




図 4.9: 2009 年 9 月の単調増加の SUN\_ALT と DIST\_PCU\_IN\_I の分布




図 4.10: 2009 年 9 月の単調減少の SUN\_ALT と DIST\_PCU\_IN\_I の分布




図 4.11: 2010 年 6 月の単調増加の SUN\_ALT と DIST\_PCU\_IN\_I の分布




図 4.12: 2010 年 6 月の単調減少の SUN\_ALT と DIST\_PCU\_IN\_I の分布




図 4.13: 2014 年 9 月の単調増加の SUN\_ALT と DIST\_PCU\_IN\_I の分布




図 4.14: 2014 年 9 月の単調減少の SUN\_ALT と DIST\_PCU\_IN\_I の分布

このデータ分布をまとめるために、新たに UP\_VALUE を作成した。UP\_VALUE は前の SUN\_ALT から、現在の SUN\_ALT を引いたものである。UP\_VALUE を追加し、2009 年 9 月のデータを基にランダムフォレスト回帰を行った結果を表 4.2 に示す。その結果、RMSE が大幅に減少し、モデルの精度が向上した。異常検知の正解率は 90% 以上となり、良好な結果を得ることができた。

表 4.2: 衛星と太陽の角度による特徴量を追加した結果

| 期間      | 正常/異常 | RMSE  | 正常データ量 | 異常データ量 | 正解率    |
|---------|-------|-------|--------|--------|--------|
| 2010/06 | 正常    | 1.104 | 13578  | 1034   | 92.92% |
| 2011/06 | 正常    | 1.134 | 4957   | 327    | 93.81% |
| 2011/08 | 正常    | 0.923 | 23104  | 781    | 96.73% |
| 2012/07 | 異常    | 5.777 | 11     | 1080   | 98.99% |
| 2014/04 | 異常    | 6.032 | 184    | 62890  | 99.70% |
| 2014/07 | 異常    | 7.130 | 124    | 16260  | 99.24% |
| 2014/09 | 異常    | 9.417 | 20     | 14921  | 99.86% |

#### 4.2.3 K-分割交差検証を追加した結果

全データを用いてモデルに学習させるとモデルが過学習に陥いる可能性があるため、K-分割交差検証を使用した。K-分割交差検証は事前に与えられるデータを全て使って学習するのではなく、一部のデータセットを検証用に分けておき、学習には利用しないという方法である。図 4.15 のように、すべてのデータをランダムに 5 分割し、そのうち 4 つを訓練データ、1 つをテストデータとして、5 回往復させる。5 回の結果を平均して、最終的な推定値の結果を求める。推定の流れを図 4.16 にまとめた。K-分割交差検証を追加したランダムフォレスト回帰の結果を表 4.3 に示す。その結果、RMSE の値が減少し、モデルの精度が向上していることが確認された。その結果、正常期間の異常検知の正解率が向上した。

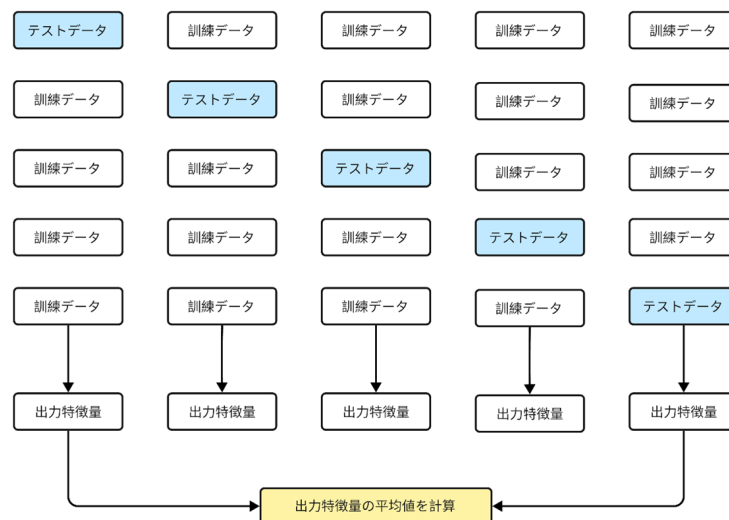


図 4.15: K-分割交差検証

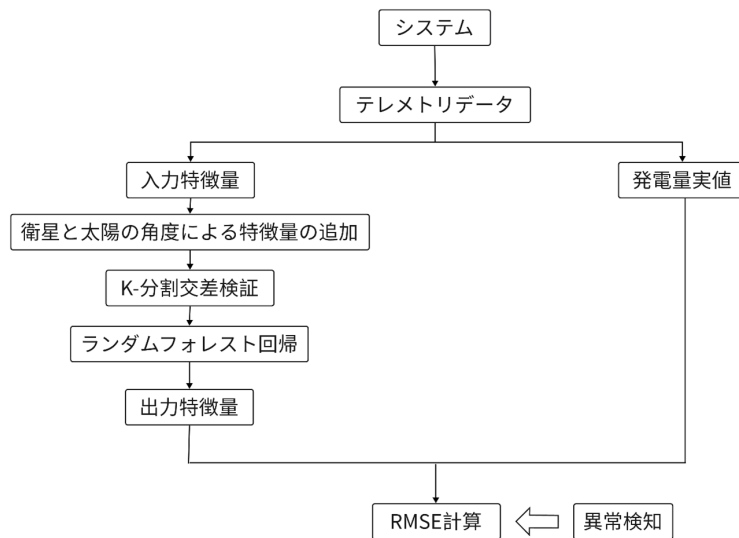


図 4.16: K-分割交差検証を追加したモデルの流れ

表 4.3: K-分割交差検証を追加した結果

| 期間 <sup>Ⓐ</sup>      | 正常/異常 <sup>Ⓐ</sup> | RMSE <sup>Ⓐ</sup>  | 正常データ量 <sup>Ⓐ</sup> | 異常データ量 <sup>Ⓐ</sup> | 正解率 <sup>Ⓐ</sup>    |
|----------------------|--------------------|--------------------|---------------------|---------------------|---------------------|
| 2010/06 <sup>Ⓐ</sup> | 正常 <sup>Ⓐ</sup>    | 1.049 <sup>Ⓐ</sup> | 14022 <sup>Ⓐ</sup>  | 590 <sup>Ⓐ</sup>    | 95.96% <sup>Ⓐ</sup> |
| 2011/06 <sup>Ⓐ</sup> | 正常 <sup>Ⓐ</sup>    | 1.060 <sup>Ⓐ</sup> | 5065 <sup>Ⓐ</sup>   | 219 <sup>Ⓐ</sup>    | 95.85% <sup>Ⓐ</sup> |
| 2011/08 <sup>Ⓐ</sup> | 正常 <sup>Ⓐ</sup>    | 0.843 <sup>Ⓐ</sup> | 23265 <sup>Ⓐ</sup>  | 620 <sup>Ⓐ</sup>    | 97.48% <sup>Ⓐ</sup> |
| 2012/07 <sup>Ⓐ</sup> | 異常 <sup>Ⓐ</sup>    | 5.761 <sup>Ⓐ</sup> | 4 <sup>Ⓐ</sup>      | 1087 <sup>Ⓐ</sup>   | 99.63% <sup>Ⓐ</sup> |
| 2014/04 <sup>Ⓐ</sup> | 異常 <sup>Ⓐ</sup>    | 5.980 <sup>Ⓐ</sup> | 115 <sup>Ⓐ</sup>    | 62959 <sup>Ⓐ</sup>  | 99.81% <sup>Ⓐ</sup> |
| 2014/07 <sup>Ⓐ</sup> | 異常 <sup>Ⓐ</sup>    | 7.313 <sup>Ⓐ</sup> | 694 <sup>Ⓐ</sup>    | 15690 <sup>Ⓐ</sup>  | 95.76% <sup>Ⓐ</sup> |
| 2014/09 <sup>Ⓐ</sup> | 異常 <sup>Ⓐ</sup>    | 9.314 <sup>Ⓐ</sup> | 18 <sup>Ⓐ</sup>     | 14923 <sup>Ⓐ</sup>  | 99.87% <sup>Ⓐ</sup> |

#### 4.2.4 パラメータ最適化を追加した結果

さらにモデルを改善するために、機械学習モデルのハイパーパラメータのベイズ最適化パッケージである Optuna（オプチュナ）を使用し、ランダムフォレスト回帰を用いてパラメータを最適化した。Optuna からパラメータを受け取るコードを記述し、その関数を Optuna に渡すと、Optuna がそのパラメータを変化させて自動的に何度もそのコードを呼び出し、最適なパラメータを発見できる。ランダムフォレスト回帰の重要なパラメータは Depth と n\_estimators である。Depth は n\_estimators で指定した回帰木の深さ、n\_estimators は利用する回帰木の数である。本研究では、合計 30 回のシミュレーションを行い、その結果を表 4.4 に示す。これより 10 回目のシミュレーションが最も良い結果であることが分かった。推定の流れを図 4.17 に、パラメータ最適化したランダムフォレスト回帰の結果を表 4.5 に示す。その結果、一部で改善が見られるものの、大きな改善には至っていないことが分かった。



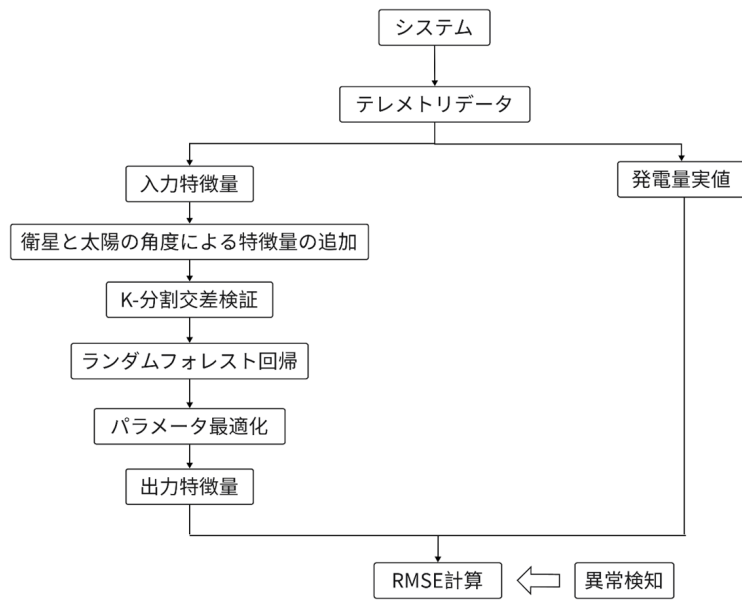


図 4.17: パラメータ最適化を追加したモデルの流れ

表 4.4: 30 回のシミュレーション結果

| trial <sup>③</sup> | n_estimators <sup>③</sup> | depth <sup>③</sup> | value <sup>③</sup>              | best_trial <sup>③</sup> |
|--------------------|---------------------------|--------------------|---------------------------------|-------------------------|
| 0 <sup>③</sup>     | 478 <sup>③</sup>          | 2 <sup>③</sup>     | 0.9086717500123243 <sup>③</sup> | 0 <sup>③</sup>          |
| 1 <sup>③</sup>     | 717 <sup>③</sup>          | 3 <sup>③</sup>     | 0.9458043991871768 <sup>③</sup> | 1 <sup>③</sup>          |
| 2 <sup>③</sup>     | 513 <sup>③</sup>          | 26 <sup>③</sup>    | 0.9614702209609034 <sup>③</sup> | 2 <sup>③</sup>          |
| 3 <sup>③</sup>     | 119 <sup>③</sup>          | 13 <sup>③</sup>    | 0.9622829603138164 <sup>③</sup> | 3 <sup>③</sup>          |
| 4 <sup>③</sup>     | 857 <sup>③</sup>          | 23 <sup>③</sup>    | 0.9615831974659728 <sup>③</sup> | 3 <sup>③</sup>          |
| 5 <sup>③</sup>     | 655 <sup>③</sup>          | 8 <sup>③</sup>     | 0.9651094270385224 <sup>③</sup> | 5 <sup>③</sup>          |
| 6 <sup>③</sup>     | 228 <sup>③</sup>          | 2 <sup>③</sup>     | 0.9084798096780805 <sup>③</sup> | 5 <sup>③</sup>          |
| 7 <sup>③</sup>     | 558 <sup>③</sup>          | 2 <sup>③</sup>     | 0.9086646666337648 <sup>③</sup> | 5 <sup>③</sup>          |
| 8 <sup>③</sup>     | 653 <sup>③</sup>          | 26 <sup>③</sup>    | 0.961477739495469 <sup>③</sup>  | 5 <sup>③</sup>          |
| 9 <sup>③</sup>     | 649 <sup>③</sup>          | 2 <sup>③</sup>     | 0.9085748466016701 <sup>③</sup> | 5 <sup>③</sup>          |
| 10 <sup>③</sup>    | 921 <sup>③</sup>          | 6 <sup>③</sup>     | 0.9662559751901083 <sup>③</sup> | 10 <sup>③</sup>         |
| 11 <sup>③</sup>    | 970 <sup>③</sup>          | 6 <sup>③</sup>     | 0.9662242839918112 <sup>③</sup> | 10 <sup>③</sup>         |
| 12 <sup>③</sup>    | 922 <sup>③</sup>          | 6 <sup>③</sup>     | 0.966254111106372 <sup>③</sup>  | 10 <sup>③</sup>         |
| 13 <sup>③</sup>    | 942 <sup>③</sup>          | 5 <sup>③</sup>     | 0.9646561647697698 <sup>③</sup> | 10 <sup>③</sup>         |
| 14 <sup>③</sup>    | 800 <sup>③</sup>          | 10 <sup>③</sup>    | 0.9639838534750715 <sup>③</sup> | 10 <sup>③</sup>         |
| 15 <sup>③</sup>    | 318 <sup>③</sup>          | 4 <sup>③</sup>     | 0.9607329480735297 <sup>③</sup> | 10 <sup>③</sup>         |
| 16 <sup>③</sup>    | 815 <sup>③</sup>          | 13 <sup>③</sup>    | 0.9625464005086135 <sup>③</sup> | 10 <sup>③</sup>         |
| 17 <sup>③</sup>    | 960 <sup>③</sup>          | 4 <sup>③</sup>     | 0.9607838623102662 <sup>③</sup> | 10 <sup>③</sup>         |
| 18 <sup>③</sup>    | 863 <sup>③</sup>          | 8 <sup>③</sup>     | 0.9652410186493826 <sup>③</sup> | 10 <sup>③</sup>         |
| 19 <sup>③</sup>    | 397 <sup>③</sup>          | 16 <sup>③</sup>    | 0.9619872564882724 <sup>③</sup> | 10 <sup>③</sup>         |
| 20 <sup>③</sup>    | 1000 <sup>③</sup>         | 3 <sup>③</sup>     | 0.9458588082805853 <sup>③</sup> | 10 <sup>③</sup>         |
| 21 <sup>③</sup>    | 898 <sup>③</sup>          | 6 <sup>③</sup>     | 0.9662242821697481 <sup>③</sup> | 10 <sup>③</sup>         |
| 22 <sup>③</sup>    | 762 <sup>③</sup>          | 6 <sup>③</sup>     | 0.9662387917480935 <sup>③</sup> | 10 <sup>③</sup>         |
| 23 <sup>③</sup>    | 748 <sup>③</sup>          | 4 <sup>③</sup>     | 0.9608239131992091 <sup>③</sup> | 10 <sup>③</sup>         |
| 24 <sup>③</sup>    | 755 <sup>③</sup>          | 10 <sup>③</sup>    | 0.964018123975617 <sup>③</sup>  | 10 <sup>③</sup>         |
| 25 <sup>③</sup>    | 868 <sup>③</sup>          | 5 <sup>③</sup>     | 0.9646001733131332 <sup>③</sup> | 10 <sup>③</sup>         |
| 26 <sup>③</sup>    | 592 <sup>③</sup>          | 7 <sup>③</sup>     | 0.9654539366813605 <sup>③</sup> | 10 <sup>③</sup>         |
| 27 <sup>③</sup>    | 912 <sup>③</sup>          | 3 <sup>③</sup>     | 0.9459263064835095 <sup>③</sup> | 10 <sup>③</sup>         |
| 28 <sup>③</sup>    | 779 <sup>③</sup>          | 10 <sup>③</sup>    | 0.963952685054857 <sup>③</sup>  | 10 <sup>③</sup>         |
| 29 <sup>③</sup>    | 438 <sup>③</sup>          | 5 <sup>③</sup>     | 0.964677562641379 <sup>③</sup>  | 10 <sup>③</sup>         |

表 4.5: パラメータ最適化を追加した結果

| 期間 <sup>Ⓐ</sup>      | 正常/異常 <sup>Ⓐ</sup> | RMSE <sup>Ⓐ</sup>  | 正常データ量 <sup>Ⓐ</sup> | 異常データ量 <sup>Ⓐ</sup> | 正解率 <sup>Ⓐ</sup>    |
|----------------------|--------------------|--------------------|---------------------|---------------------|---------------------|
| 2010/06 <sup>Ⓐ</sup> | 正常 <sup>Ⓐ</sup>    | 1.076 <sup>Ⓐ</sup> | 14012 <sup>Ⓐ</sup>  | 600 <sup>Ⓐ</sup>    | 95.89% <sup>Ⓐ</sup> |
| 2011/06 <sup>Ⓐ</sup> | 正常 <sup>Ⓐ</sup>    | 1.032 <sup>Ⓐ</sup> | 5122 <sup>Ⓐ</sup>   | 162 <sup>Ⓐ</sup>    | 96.93% <sup>Ⓐ</sup> |
| 2011/08 <sup>Ⓐ</sup> | 正常 <sup>Ⓐ</sup>    | 0.840 <sup>Ⓐ</sup> | 23376 <sup>Ⓐ</sup>  | 509 <sup>Ⓐ</sup>    | 97.86% <sup>Ⓐ</sup> |
| 2012/07 <sup>Ⓐ</sup> | 異常 <sup>Ⓐ</sup>    | 5.698 <sup>Ⓐ</sup> | 4 <sup>Ⓐ</sup>      | 1087 <sup>Ⓐ</sup>   | 99.63% <sup>Ⓐ</sup> |
| 2014/04 <sup>Ⓐ</sup> | 異常 <sup>Ⓐ</sup>    | 5.808 <sup>Ⓐ</sup> | 340 <sup>Ⓐ</sup>    | 62734 <sup>Ⓐ</sup>  | 99.46% <sup>Ⓐ</sup> |
| 2014/07 <sup>Ⓐ</sup> | 異常 <sup>Ⓐ</sup>    | 7.031 <sup>Ⓐ</sup> | 222 <sup>Ⓐ</sup>    | 16162 <sup>Ⓐ</sup>  | 98.64% <sup>Ⓐ</sup> |
| 2014/09 <sup>Ⓐ</sup> | 異常 <sup>Ⓐ</sup>    | 9.229 <sup>Ⓐ</sup> | 18 <sup>Ⓐ</sup>     | 14923 <sup>Ⓐ</sup>  | 99.87% <sup>Ⓐ</sup> |

## 第 5 章

### 考察

#### 5.1 推定精度の考察

##### 5.1.1 機械学習モデルの推定精度

ランダムフォレスト回帰モデルについて、各改善策の結果と各特徴量の重要性を考察する。表 4.1, 4.2, 4.3, 4.5 に示すように、3 つの改善策によりほとんどの期間で RMSE が小さくなり、モデルの推定精度も向上する。

推定精度に対する、各特徴量の重要性を考察する。ランダムフォレスト回帰モデルは、ある特徴量の値をランダムに動かして予測を行うため、一般的に推定精度は下がる。その結果ランダム動作で大きく推定精度が変化した特徴量が、重要な特徴量であると判断される。逆にランダム動作してもたいして精度の変わらない特徴量は、もともとこのモデルにとって重要な特徴量ではなかったということになる。したがって、図 5.1～5.3 で示すように、充電量の推定においては改善方法が変わり、UP\_VALUE, SAT\_ALT, SUN\_ALT の重要度が変化したため、重要な特徴量であると判断される。一方で、FOC\_RA, FOC\_DEC, EULER1, EULER2, EULER3 の重要度はほとんどないことが分かる。




図 5.1: 衛星と太陽の角度による特徴量を追加したモデルの特徴量の重要性




図 5.2: K-分割交差検証を追加したモデルの特徴量の重要性




図 5.3: パラメータ最適化を追加したモデルの特徴量の重要性

### 5.1.2 データ量による推定精度の変化

データ量がモデルの精度に影響を与えることがある。本研究のモデル精度がデータ量によりどのように変化するかを見るために、2009 年 9 月のデータを 1,000 個ごとに分割し、モデルを構築した。異常期間では RMSE が大きすぎて意味をなさないため、正常期間のデータをモデルで比較し、RMSE を求めた。図 5.4 を示すように、RMSE はデータ量の増加とともに小さくなり、安定となった。

また、2010 年 6 月の総データ量は 2009 年 9 月の総データ量より少ないため、2010 年 6 月のデータを 1,000 個ごとに分割し、モデルを構築した。図 5.5 に示すように、2010 年 6 月の RMSE はデータ量が増えるにつれて小さくなっており、この傾向は 2009 年 9 月と同じである。しかし、2010 年 6 月の総データ量は 2009 年 9 月の総データ量より少ないた

め、2010年6月のRMSEは2009年9月のRMSEより大きい。つまり、2010年6月のデータで構築したモデルの推定精度は、2009年9月のモデルの推定精度より低い。したがって、データ量が増えれば増えるほど、モデルの推定精度は高くなると考えられる。




図 5.4: 2009 年 9 月のデータに基づくモデルの推定精度の変化




図 5.5: 2010 年 6 月のデータに基づくモデルの推定精度の変化

## 5.2 異常検知結果の考察

### 5.2.1 概要

前章ではモデルの推定精度を考察したが、本章ではモデルの推定精度によって得られる異常検知結果を考察する。まず、機械学習の一般的な評価方法を用いて、モデルの最終

的な異常検知結果が良好であるかどうかを考察する．そして，モデルによって正しく予測されなかった異常データは，何が原因で正しく予測されなかったかを分析する．また，本研究のモデルの異常検知はリミットチェックによって実現されているため，リミットチェックの閾値が異なると異常検知の結果も異なると考えられる．そこで，閾値を変えて，どのような違いが生じるかを考察する．最後に，異なる期間のデータで構築したモデルの異常検知結果がどのように変化するかを考察する．

### 5.2.2 異常検知の精度評価

リミットチェックにより異常検知することは分類問題のため，機械学習の分類の評価指標で異常検知の結果を評価する．分類において使う主な評価指標は混同行列，正解率，適合率，再現率，F 値である．

混同行列は二値分類（正常データと異常データの予測）の結果をまとめた表である．分類結果を表形式にまとめることより，どのラベルを正しく分類し，どのラベルを誤って分類したかを調べる事が出来る．真の値と予測した値の組み合わせには，それぞれ名称があり，以下の図 5.6 ように呼ばれる．本研究では正事例は正常データ，負事例は異常データである．そして，2011 年 11 月以前のデータを正常であると判断して用いているため，2011 年 11 月以前のデータは正常データと判断された場合は TP，異常データと判断された場合は FN とする．一方，2011 年 11 月以後のデータは正常データと判断された場合は FP，異常データと判断された場合は TN とする．本節は表 4.5 と比較しながら，2009 年 9 月のデータを基づく改善したモデルの結果を評価する．

|     |     | 予測値 |     |
|-----|-----|-----|-----|
|     |     | 負事例 | 正事例 |
| 真の値 | 負事例 | TN  | FP  |
|     | 正事例 | FN  | TP  |

図 5.6: 混同行列の定義

正解率は予測結果全体がどれくらい真の値と一致しているかを表す指標であり，式 (10)

で求められる。

$$\text{正解率} = \frac{TP + TN}{TP + FP + FN + TN} \quad (10)$$

適合率は、正事例と予測したもののなかで真の値が正事例の割合を表す指標である。式 (11) で求められる。

$$\text{適合率} = \frac{TP}{TP + FP} \quad (11)$$

再現率とは、真の値が正事例のものなかで正事例と予測した割合を表す指標である。式 (12) で求められる。

$$\text{再現率} = \frac{TP}{TP + FN} \quad (12)$$

F 値は、適合率と再現率の調和平均により、計算される。式 (13) で求められる。

$$\text{F 値} = \frac{2 \times \text{適合率} \times \text{再現率}}{\text{適合率} + \text{再現率}} \quad (13)$$

改善されたモデルの異常検知評価を表 5.1 にまとめる。これより、良好な評価結果が得られたことが分かる。

表 5.1: 異常検知の精度評価結果

|    |       |     |        |
|----|-------|-----|--------|
| TP | 42510 | 正解率 | 97.90% |
| TN | 94906 | 適合率 | 98.64% |
| FP | 584   | 再現率 | 94.74% |
| FN | 2358  | F 値 | 96.65% |

### 5.2.3 異常データ分布結果

データが正しく検出されているかどうかを見るために、2009 年 9 月のデータで構築したモデルの各期間の異常データ分布を図 5.8～5.14 にまとめる。そして、モデル構築の 2009 年 9 月の総データ分布を図 5.7 に示す。

図 4.3 により、DIST\_PCU\_IN\_I の 20 付近は SUN\_ALT の単調増加と単調減少の分岐点である。SUN\_ALT の単調増加と単調減少により、充電量は変化する。各正常期間の異常検知した異常データ分布を示す図 5.8～5.10 から、異常データの多くが 20 付近に集まる。したがって、異常データは分岐点付近で発生していることがわかり、この範囲内でモデルがうまく推定できないことと考えられる。

各異常期間の異常データの推定成功率が約 99 % のモデルであることから、異常検知し

た異常データ分布は異常期間の総データ分布とほぼ同じと考えられる．各異常期間の異常検知した異常データ分布を示す図 5.10～5.14 により，2009 年 9 月のデータの分布を示す図 5.7 と比較すると，データの分布が大きく異なることが分かった．したがって，各異常期間のデータは，正常期間から大きく逸脱したデータである．つまり，異常期間のデータがリミットチェックの閾値を大きく超えているため，異常データと判断されることになる．




図 5.7: 2009 年 9 月のデータの分布




図 5.8: 2010 年 6 月の異常データの分布





図 5.9: 2011 年 6 月の異常データの分布




図 5.10: 2011 年 8 月の異常データの分布



図 5.11: 2012 年 7 月の異常データの分布




図 5.12: 2014 年 4 月の異常データの分布



図 5.13: 2014 年 7 月の異常データの分布



図 5.14: 2014 年 9 月の異常データの分布

#### 5.2.4 閾値による異常検知結果の変化

リミットチェック法は、事前に設定された適正な閾値（上限値と下限値）に収まっているかどうかを監視し、システムの正常・異常を判断するというものである。閾値により、異なる異常検知結果を得ることができる。従来の閾値設定は、データの平均と分散に基づいて異常を判断するものであった。このため、平均値から分散の2倍を引いた閾値を設定し、異常検知を行った。その結果を表5.2に示す。表4.5と比較すると、正常期間時は2倍RMSE閾値の正解率が高いが、異常期間時は平均値から分散の2倍を引いた閾値の方が高いことが分かる。

表 5.2: 平均値から分散の2倍を引いた閾値の結果

| 期間      | 正常/異常 | 正常データ量 | 異常データ量 | 正解率    |
|---------|-------|--------|--------|--------|
| 2010/06 | 正常    | 13708  | 904    | 93.81% |
| 2011/06 | 正常    | 5057   | 227    | 95.70% |
| 2011/08 | 正常    | 23197  | 688    | 97.11% |
| 2012/07 | 異常    | 3      | 1088   | 99.72% |
| 2014/04 | 異常    | 91     | 62983  | 99.85% |
| 2014/07 | 異常    | 97     | 16287  | 99.40% |
| 2014/09 | 異常    | 15     | 14926  | 99.89% |

#### 5.2.5 運用期間による異常検知結果の変化

総データ量が変わるとモデルの推定精度も変わるので、総データ量が変わるときモデルの異常検知結果がどうなるかを考察する。このため、2010年6月のデータを基づくモデルを構築する。閾値を2倍RMSEの結果を表5.3に、閾値を平均値から分散の2倍を引いたものの結果を表5.4に示す。結果から見ると、2009年9月のデータを基づくモデルよりかなり悪くなった。異常データを考察するため、2010年6月のデータで構築したモデルの2倍RMSEの閾値の異常データ分布を図5.16～5.22にまとめ、平均値から分散の2倍を引いた閾値異常データ分布を図5.23～5.29にまとめる。また、モデル構築の2010年6月のデータ分布を図5.15に示す。

図5.5と図5.15から、2009年9月と2010年6月のデータ分布は基本的に同じであることが再確認できるが、2010年6月のデータ量はより少ない。

図5.16から、異常データは21～25付近に集まるため、モデルは分岐点付近とSUN\_ALTの単調増加のデータがうまく異常検知できないことが分かる。図5.17、5.18から、異常検知結果が良いが、SUN\_ALTの単調減少のデータが異常検知できないデータがある。ま

た，異常期間の検知結果から，2014 年 4 月の結果がかなり悪い．図 5.11 と図 5.20 を比較すると，2009 年 9 月のデータで構築したモデルは 17 付近の異常データを検知できるが，2010 年 6 月のデータで構築したモデルは 17 付近の異常データを検知できない．そして，図 5.19～5.22 から，2014 年 4 月以外の期間のデータは 17 付近のデータが少ないことから，これは 2014 年 4 月以外の異常期間の異常検知結果が良い理由と考えられる．つまり，閾値は 2 倍 RMSE の時，2010 年 6 月のデータで構築したモデルが分岐点と 17 付近，そして SUN\_ALT の単調増加の時の異常検知能力が弱い．

閾値は平均値から分散の 2 倍を引いた時，図 5.23～5.25 から，モデルが 23 付近に異常検知できる．しかし，それ以外の範囲のデータに対する異常検知の結果は悪い．また，異常期間にも同様の傾向があると考えられる．図 5.26～5.29 から，異常期間の異常検知結果が良いが，異常期間のデータ分布は，23 付近ではない．つまり，本モデルは 23 付近のデータに対してのみ異常検知できると考えられる．

以上より，データ量が少ない時，2 倍 RMSE の閾値の異常検知結果が より良い．

表 5.3: 運用期間による 2 倍 RMSE の閾値の結果

| 期間 <sup>Ⓐ</sup>      | 正常/異常 <sup>Ⓐ</sup> | RMSE <sup>Ⓐ</sup>  | 正常データ量 <sup>Ⓐ</sup> | 異常データ量 <sup>Ⓐ</sup> | 正解率 <sup>Ⓐ</sup>    |
|----------------------|--------------------|--------------------|---------------------|---------------------|---------------------|
| 2009/09 <sup>Ⓐ</sup> | 正常 <sup>Ⓐ</sup>    | 1.827 <sup>Ⓐ</sup> | 25397 <sup>Ⓐ</sup>  | 7968 <sup>Ⓐ</sup>   | 76.11% <sup>Ⓐ</sup> |
| 2011/06 <sup>Ⓐ</sup> | 正常 <sup>Ⓐ</sup>    | 1.149 <sup>Ⓐ</sup> | 4921 <sup>Ⓐ</sup>   | 363 <sup>Ⓐ</sup>    | 93.13% <sup>Ⓐ</sup> |
| 2011/08 <sup>Ⓐ</sup> | 正常 <sup>Ⓐ</sup>    | 0.933 <sup>Ⓐ</sup> | 23444 <sup>Ⓐ</sup>  | 441 <sup>Ⓐ</sup>    | 98.15% <sup>Ⓐ</sup> |
| 2012/07 <sup>Ⓐ</sup> | 異常 <sup>Ⓐ</sup>    | 4.613 <sup>Ⓐ</sup> | 73 <sup>Ⓐ</sup>     | 1018 <sup>Ⓐ</sup>   | 93.30% <sup>Ⓐ</sup> |
| 2014/04 <sup>Ⓐ</sup> | 異常 <sup>Ⓐ</sup>    | 3.672 <sup>Ⓐ</sup> | 17571 <sup>Ⓐ</sup>  | 45503 <sup>Ⓐ</sup>  | 72.14% <sup>Ⓐ</sup> |
| 2014/07 <sup>Ⓐ</sup> | 異常 <sup>Ⓐ</sup>    | 5.155 <sup>Ⓐ</sup> | 1459 <sup>Ⓐ</sup>   | 14925 <sup>Ⓐ</sup>  | 91.09% <sup>Ⓐ</sup> |
| 2014/09 <sup>Ⓐ</sup> | 異常 <sup>Ⓐ</sup>    | 6.505 <sup>Ⓐ</sup> | 1136 <sup>Ⓐ</sup>   | 13805 <sup>Ⓐ</sup>  | 92.39% <sup>Ⓐ</sup> |

表 5.4: 運用期間による平均値から分散の 2 倍を引いた閾値の結果

| 期間 <sup>Ⓐ</sup>      | 正常/異常 <sup>Ⓐ</sup> | RMSE <sup>Ⓐ</sup>  | 正常データ量 <sup>Ⓐ</sup> | 異常データ量 <sup>Ⓐ</sup> | 正解率 <sup>Ⓐ</sup>    |
|----------------------|--------------------|--------------------|---------------------|---------------------|---------------------|
| 2009/09 <sup>Ⓐ</sup> | 正常 <sup>Ⓐ</sup>    | 1.827 <sup>Ⓐ</sup> | 11197 <sup>Ⓐ</sup>  | 22168 <sup>Ⓐ</sup>  | 33.55% <sup>Ⓐ</sup> |
| 2011/06 <sup>Ⓐ</sup> | 正常 <sup>Ⓐ</sup>    | 1.149 <sup>Ⓐ</sup> | 2632 <sup>Ⓐ</sup>   | 2652 <sup>Ⓐ</sup>   | 49.81% <sup>Ⓐ</sup> |
| 2011/08 <sup>Ⓐ</sup> | 正常 <sup>Ⓐ</sup>    | 0.933 <sup>Ⓐ</sup> | 13803 <sup>Ⓐ</sup>  | 10082 <sup>Ⓐ</sup>  | 57.78% <sup>Ⓐ</sup> |
| 2012/07 <sup>Ⓐ</sup> | 異常 <sup>Ⓐ</sup>    | 4.613 <sup>Ⓐ</sup> | 2 <sup>Ⓐ</sup>      | 1089 <sup>Ⓐ</sup>   | 99.81% <sup>Ⓐ</sup> |
| 2014/04 <sup>Ⓐ</sup> | 異常 <sup>Ⓐ</sup>    | 3.672 <sup>Ⓐ</sup> | 1359 <sup>Ⓐ</sup>   | 61715 <sup>Ⓐ</sup>  | 97.84% <sup>Ⓐ</sup> |
| 2014/07 <sup>Ⓐ</sup> | 異常 <sup>Ⓐ</sup>    | 5.155 <sup>Ⓐ</sup> | 16 <sup>Ⓐ</sup>     | 16368 <sup>Ⓐ</sup>  | 99.90% <sup>Ⓐ</sup> |
| 2014/09 <sup>Ⓐ</sup> | 異常 <sup>Ⓐ</sup>    | 6.505 <sup>Ⓐ</sup> | 11 <sup>Ⓐ</sup>     | 14930 <sup>Ⓐ</sup>  | 99.92% <sup>Ⓐ</sup> |




図 5.15: 2010 年 6 月のデータの分布




図 5.16: 2009 年 9 月の異常データの分布 (2 倍 RMSE)



図 5.17: 2011 年 6 月の異常データの分布 (2 倍 RMSE)




図 5.18: 2011 年 8 月の異常データの分布 (2 倍 RMSE)



図 5.19: 2012 年 7 月の異常データの分布 (2 倍 RMSE)



図 5.20: 2014 年 4 月の異常データの分布 (2 倍 RMSE)




図 5.21: 2014 年 7 月の異常データの分布 (2 倍 RMSE)




図 5.22: 2014 年 9 月の異常データの分布 (2 倍 RMSE)




図 5.23: 2009 年 9 月の異常データの分布 (平均値から分散の 2 倍を引いた)




図 5.24: 2011 年 6 月の異常データの分布 (平均値から分散の 2 倍を引いた)




図 5.25: 2011 年 8 月の異常データの分布 (平均値から分散の 2 倍を引いた)



図 5.26: 2012 年 7 月の異常データの分布 (平均値から分散の 2 倍を引いた)






図 5.27: 2014 年 4 月の異常データの分布 (平均値から分散の 2 倍を引いた)




図 5.28: 2014 年 7 月の異常データの分布 (平均値から分散の 2 倍を引いた)



図 5.29: 2014 年 9 月の異常データの分布 (平均値から分散の 2 倍を引いた)

## 第 6 章

### 結論

#### 6.1 結論

本論文では、軌道上での自律的な異常検知に向けて、機械学習による衛星データを用いた異常検知の手法の提案を行った。

第 2 章では、データにおける代表的な異常や、機械学習の種類と従来の異常検知手法について示した。

第 3 章では、衛星データ特徴や、衛星データに応じた機械学習モデルと異常検知の方法を示した。

第 4 章では、第 3 章で提案した方法を実データへ適用し、各改善策の RMSE と異常検知正解率の結果を示した。

第 5 章では、適用結果の考察を行った。各改善策後のモデル推定精度から比較し、妥当性を確認した。また、異常検知結果の評価や閾値の設定方法などの考察を行った。

以上の結果から、以下の結論を得た。

1. 衛星データを用いた太陽電池発電量の推定モデルを構築した。
2. 推定した発電量により異常検知を行った。

#### 6.2 今後の課題

今後の課題として、この推定モデルは複数衛星、特にコンステレーションを構成する衛星群に対して適用できる可能性がある。例えば、衛星 1 のデータより推定モデルを構築し、これを衛星 2 に適用して関連データを入力し、その発電量を予測できる。そして、衛星 2 の推定した発電量と実際の発電量に異常検知を行う。この結果が良好であれば、本研究の成果を複数衛星の異常検知へ拡張できる可能性を示すことができる。

一方で、本モデルは単調増加と単調減少の分岐点においての異常検知が悪いため、改善策が必要である。

## 謝辞

最初に研究室に入った時に、何も分からなかったし、みなさんに迷惑をかける一方でした。それにも関わらず、丁寧に色々教えていただきました。2019年から来日した以来、一番成長を感じたのは佐原研の二年間でした。

本研究を進めるにあたり、約2年間にわたってご指導をいただいた佐原宏典教授、古本政博助教には深く感謝を申し上げます。毎回のMTGで衛星システムに関する専門的な知識、機械学習の知識など、常に新しい知識を教えてくださいました。このようなディスカッションミーティング場を提供していただき、ありがとうございます。

研究室に外国人が私一人だから、時々緊張することもありました。いつも場を盛り上げ、コミュニケーションをとってくださった安平さん、佐々木さん、早友さん、東君、小野君、白井君に感謝します。小野君、指田君と一緒に中華料理が楽しかったです。勝部君のアドバイスがないと、私は研究の衛星データ収集などの一つ一つのタスクを完成することができません。朝野さんとあまり交流がなかったが、朝野さんの話に耳を傾け、とても面白い人です。彼女のお陰で研究室はより楽しくなりました。後輩の塩さん、岡野さん、茂木さん、飯島君、伊藤君から色々な生活のアドバイスを頂き、ありがとうございます。

最後に、両親に感謝したいです。いつも私がやりたいことを支えてくれて、ありがとうございます。両親の支えがないと、充実した日本留学生活ができません。

## 参考文献

- [1] 土方嘉徳 et al. 「第 3 次人工知能ブームのすべて」. **エコノフォーラム 21: 学生と教職員のインターコミュニケーション誌**, (25):3–5, 2019.
- [2] 深層学習. 「異常検知と変化検知」 井出 剛・杉山 将 著. *Medical Imaging Technology*, 34(3), 2016.
- [3] 矢入健久. テレメトリマイニング: 宇宙システム異常検知・故障診断問題への機械学習的アプローチ (i 特集: 「宇宙開発と ai」 ). **人工知能**, 21(1):33–38, 2006.
- [4] 勝部駿 and 佐原宏典. システムの健康状態を表現する変数を用いた異常検知手法の検討. **日本航空宇宙学会論文集**, 70(1):1–6, 2022.
- [5] Darts, [オンライン], [<https://darts.isas.jaxa.jp/index.htm>], 2021.
- [6] Darts, [オンライン], [<http://www.astro.isas.jaxa.jp/suzaku>], 2021.
- [7] 茂原正道 and 鳥山芳夫. 衛星設計入門. **培風館**, 2002.
- [8] 前田良知. バテてもめげない bat (充電式電池), サッパリわからん sap (太陽電池)(「すぎく」10 周年記念特集 (3)). **天文月報** = *The astronomical herald*, 109(1):14–20, 2016.
- [9] 【python】ランダムフォレスト回帰のモデル作成と評価方法 | scikit-learn・機械学習による回帰分析入門, [<https://di-acc2.com/programming/python/13877/>], 2021.