

# 機械学習を用いた宇宙機の故障検知

杉江 卓哉<sup>1</sup>, 梅津 里香<sup>1</sup>, 竹島 敏明<sup>2</sup>, 海老沢 研<sup>2</sup>, 長瀬 雅之<sup>1</sup>, 湖海 亮<sup>1</sup>

1:株式会社セック 2:宇宙航空研究開発機構宇宙科学研究所



# 目次

---

- 会社概要・本研究の目的
- 機械学習を用いた故障の予兆検知
  - 機械学習の流れ
  - データ前処理
  - モデル構築
  - モデル評価
- まとめと今後の展開

# 会社概要

## 株式会社セック

# Systems Engineering Consultants Co.,LTD.

システムズエンジニアリング（システム工学）を究めたプロの技術者集団を目指す

## プロフィール

- 設立 1970年5月
- 事業内容 リアルタイムソフトウェア及びソリューションの提供
- 上場市場 東証第一部  
(2004年 JASDAQ上場、2017年市場変更)
- 証券コード 3741
- 資本金 4億7,730万円
- 従業員数 269名 (2017/4/1)
- 本社住所 東京都世田谷区用賀 4-10-1  
世田谷ビジネススクエア
- 主要顧客及び取引先
  - ◆ 大手通信キャリア、大手電機メーカー
  - ◆ 研究機関（国立研究開発法人 情報通信研究機構、宇宙航空研究開発機構など）

東京本社



東京都世田谷区用賀  
世田谷ビジネススクエア

大阪事業所




大阪市淀川区西中島  
新大阪プライムタワー

## 人類の夢を叶えるソフトウェア

科学衛星や探査機の搭載システム、観測データ解析システムなどの開発と、次世代ロボットに関する研究開発、サービスロボットシステムの開発をしています。

衛星搭載システム  
(ようこう、はやぶさ2など)



天体望遠鏡制御システム  
(すばる望遠鏡など)



スーパーコンピュータ  
利用者・管理者ポータル



研究機関向けシステム  
(NICT、JAXA、大学など)



車両自動走行



ロボット  
(RTM、ROS、AI)



# 業務実績 > 宇宙機（探査機、人工衛星、ISS）搭載システム

## 宇宙の謎を解き明かす

宇宙機搭載システムにおいて、以下の得意技術で貢献しております。

- (1) 探査機における自動化、自律化制御、画像処理（リアルタイム制御技術）
- (2) 科学観測機器用データ処理（乏しい計算資源における科学データ、画像の処理技術）
- (3) データ喪失が許されない記録装置開発（高信頼/高可用性ソフトウェア開発技術）

### リアルタイム制御技術




小惑星探査機 はやぶさ




小惑星探査機はやぶさ2



金星探査機 あかつき



ソーラセイル実証機  
IKAROS



宇宙探査ロボット  
開発支援

### データ処理技術



太陽観測衛星ようこう




太陽観測衛星ひので



X線天文衛星あすか



X線天文衛星すざく



全天X線観測装置MAXI




(月探査機LUNAR-A)

### 高信頼/高可用性開発技術



水循環変動観測衛星すざく



気候変動観測衛星GCOM-C



温室効果ガス観測技術衛星いぶ  
き



先鋒的宇宙システムASVAROシリーズ

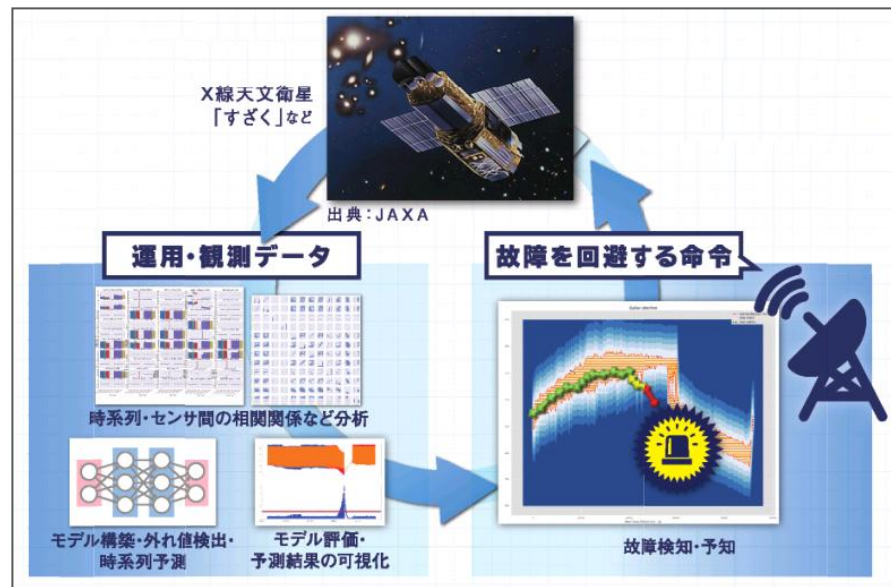


※主要な担当実績

# 本研究の背景及び目的

## ■ 背景

- 宇宙機は安全性、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。
- 宇宙機は10年程度運用される場合が多く、**膨大な運用データ・観測データ**が存在する。
- 宇宙機は、運用中に**故障する機器**があり、**異常や故障の予兆を早期に検出**することは、安定運用のための重要なファクターである。



## ■ 本研究の目的

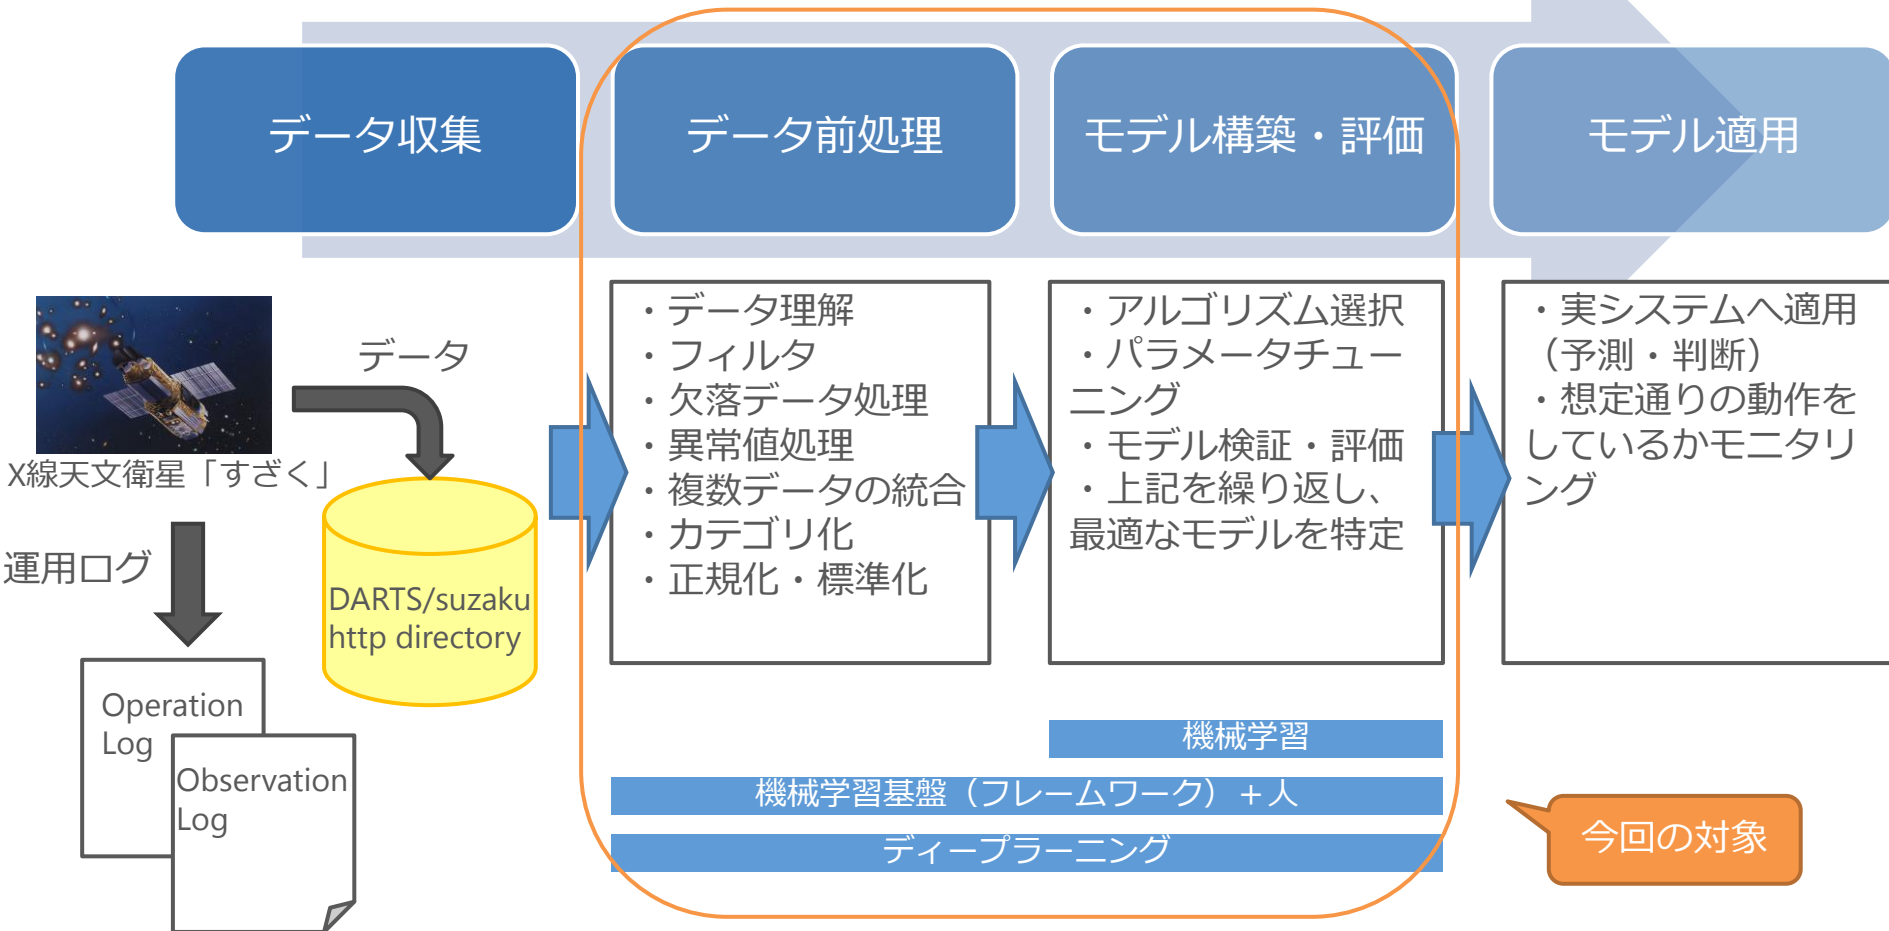
- **機械学習技術**を用いて、宇宙機の運用中に発生した**出来事と運用データの関係性を学習**し、機器の故障を早期に捉えたり、故障に繋がる予兆を検出するためのモデルを構築する。
- 将来的には、作成した学習済みモデルや、モデル導出ノウハウを活用して、今後**打ち上がる宇宙機の故障検知、故障予知に繋げる**。

---

# 機械学習を用いた故障の予兆検知



# 機械学習を用いた故障の予兆検知 機械学習の流れ





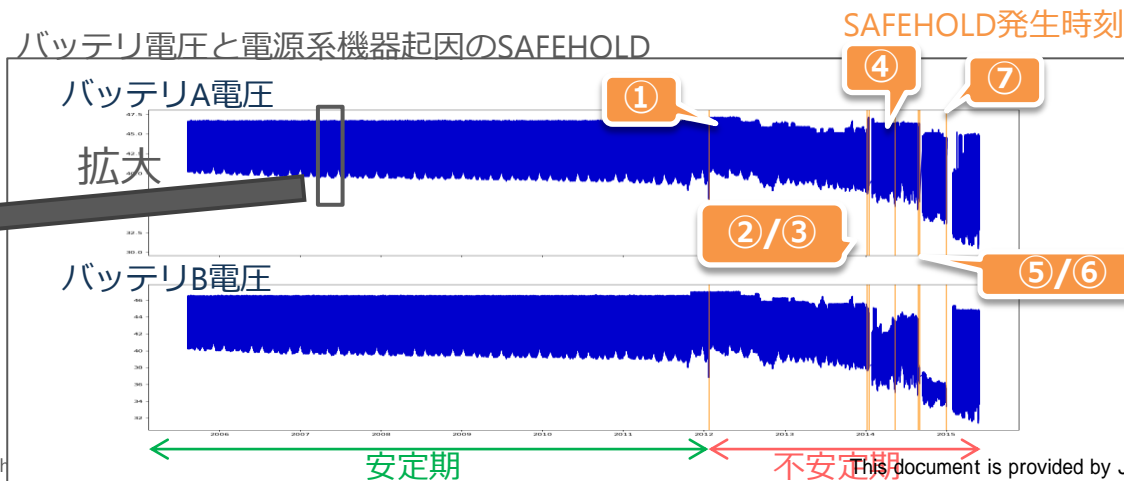

# 機械学習を用いた故障の予兆検知 データ前処理 対象データ

## ■ 対象データ

- X線天文衛星「すざく」
  - ◆ 期間：2005年7月～2015年8月
  - ◆ 軌道：円軌道
  - ◆ 軌道周期：96分
- 消耗が激しく、故障が多い**電源系機器**の故障の予兆を検知する  
衛星運用中に発生したSAFEHOLDのうち、電源系機器の異常が原因と見られる**SAFEHOLD**の発生を検出することを目標とする  
※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



X線天文衛星「すざく」出展：JAXA



# 機械学習を用いた故障の予兆検知 データ前処理 データ取得

## ■ データ取得

### ● 衛星出力データ

Suzaku Public Data(DARTS)\*1

#### ◆ House Keeping(HK) Data

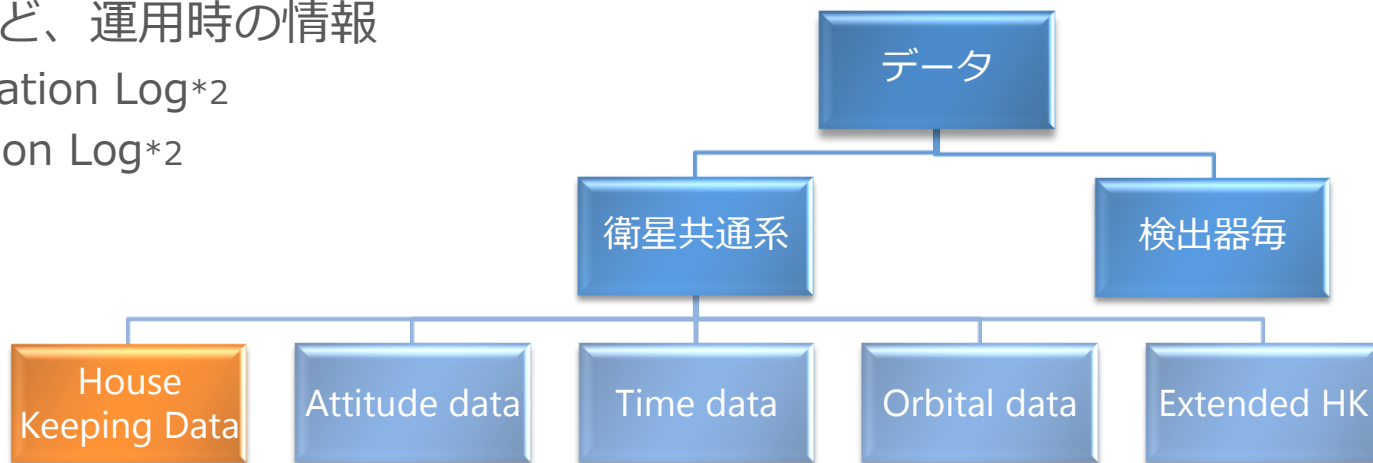
- 衛星の状態を知るためのデータ
- 23種類のコンポーネント情報、約5000項目が含まれている  
例: 電源関連、熱制御関連、データ処理関連、姿勢制御関連 etc...

### ● 異常発生など、運用時の情報

- ◆ Observation Log\*2
- ◆ Operation Log\*2

\*1 : <http://darts.isas.jaxa.jp/pub/suzaku/>

\*2 : <http://www.astro.isas.jaxa.jp/suzaku/log/>


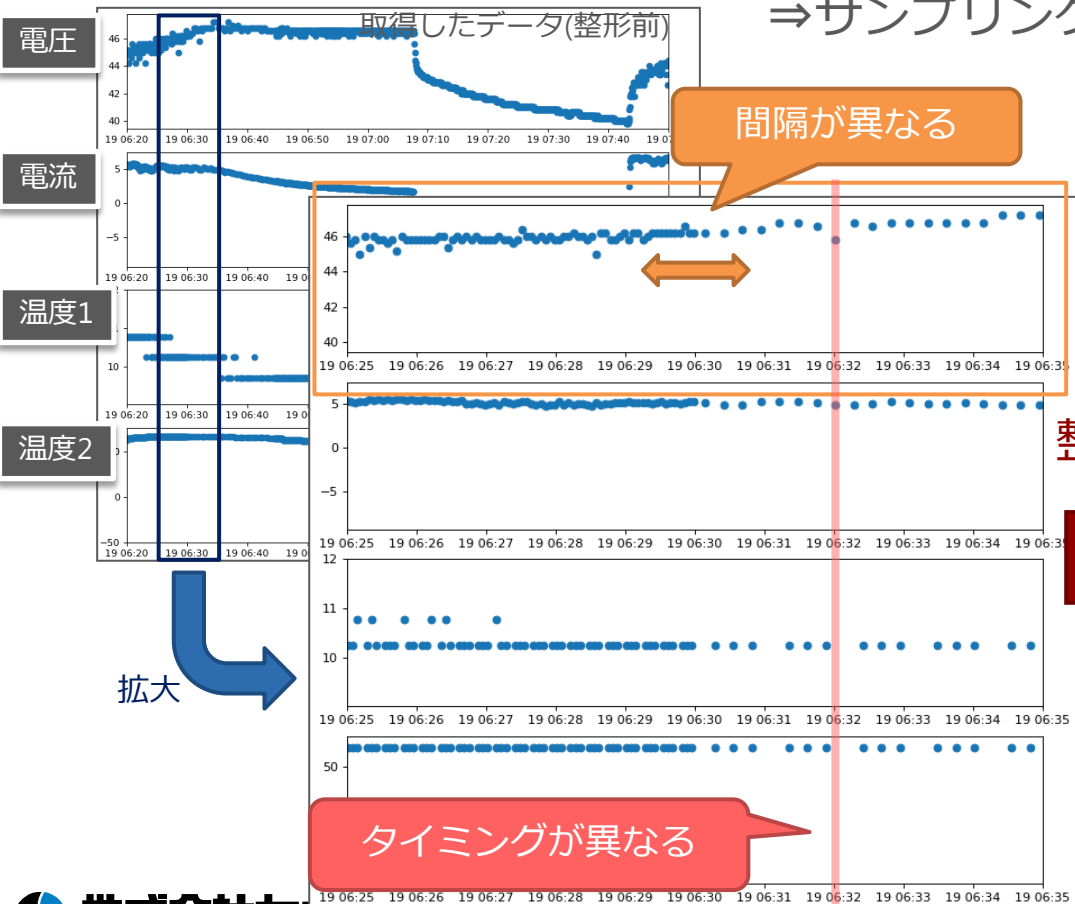


衛星から出力されるデータの構成

# 機械学習を用いた故障の予兆検知 データ前処理 データ整形

■ 取得したデータそのままでは機械学習に使用できない

⇒ サンプル間隔・タイミングの変換などを実施



# 機械学習を用いた故障の予兆検知 モデル構築 手法一覧

- 下記アルゴリズムでモデルを構築し、検証を行った
- 訓練データを学習したもののから異常度を算出し、異常度が大きいものを故障の予兆と捉える

**時系列データを用いた異常検出**

- kNN
- 特異スペクトル変換
- ARMA/SARMA
- 状態空間モデル
- RNN
- LSTM

**次元削減を用いた異常検出**

- PCA
- AutoEncoder

**データの分布を用いた異常検出**

- カーネル密度推定法
- 混合正規分布
- OneClassSVM

本発表では、それぞれのカテゴリから4手法での確認状況を紹介する

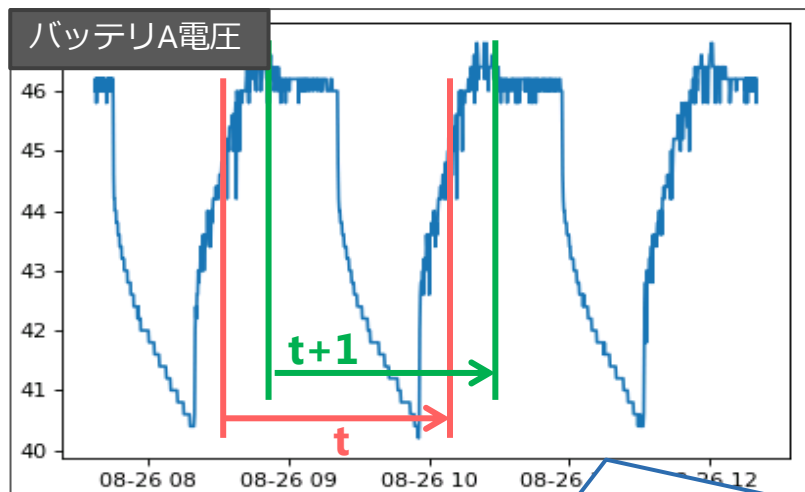
# 機械学習を用いた故障の予兆検知 モデル構築 kNN 1/2

## ■ kNN(k近傍法)

- k個の最近傍データとの距離を測定する
- 異常度の算出に時間がかかる

## ■ 異常度の算出


- 部分時系列を学習する
- 正常時の部分時系列は近くに、異常時の部分時系列は遠くに存在すると仮定



1周期=96分 ⇒ 144次元(40秒刻み)として部分時系列を作成

	144次元
t	[40.5, 41.2, 42.5, … 40.0]
t+1	[41.2, 42.5, 43.3, … 42.0]

正常群




kNN異常判定

異常

最近傍までの距離を異常度とし、一定値以上、異常度が高いものを異常とみなす

# 機械学習を用いた故障の予兆検知 モデル構築 kNN 2/2

異常度



安定期

不安定期

■ 直近1ヶ月(約60,000点)を学習して予兆検知

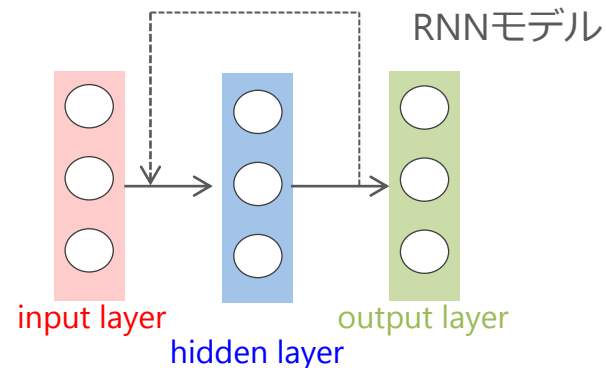
	①	②	③	④	⑤	⑥	⑦
検出可能時間	1日10時間前	×	3日23時間前	×	×	×	1日16時間前

	評価
SAFEHOLD検出	3/7
安定期誤報	△
不安定期誤報	△
失報	△

# 機械学習を用いた故障の予兆検知 モデル構築 RNN 1/2

## ■ RNN(Recurrent Neural Network)

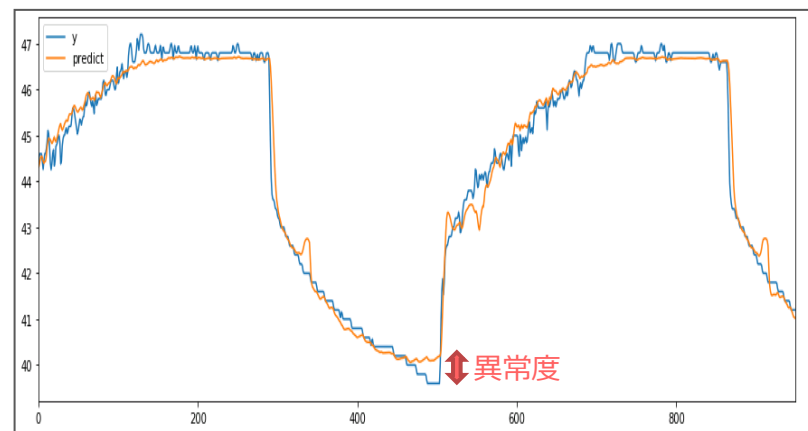
- ニューラルネットワーク(NN)の一種
- 過去の隠れ層を取り入れることにより、時系列データを予測



## ■ 異常度の算出

- 数点前の連続値(部分時系列、1周期より短い期間を使用)と現在の値を紐づけて学習
- 異常の場合は、学習した結果からは予測できない値になると仮定

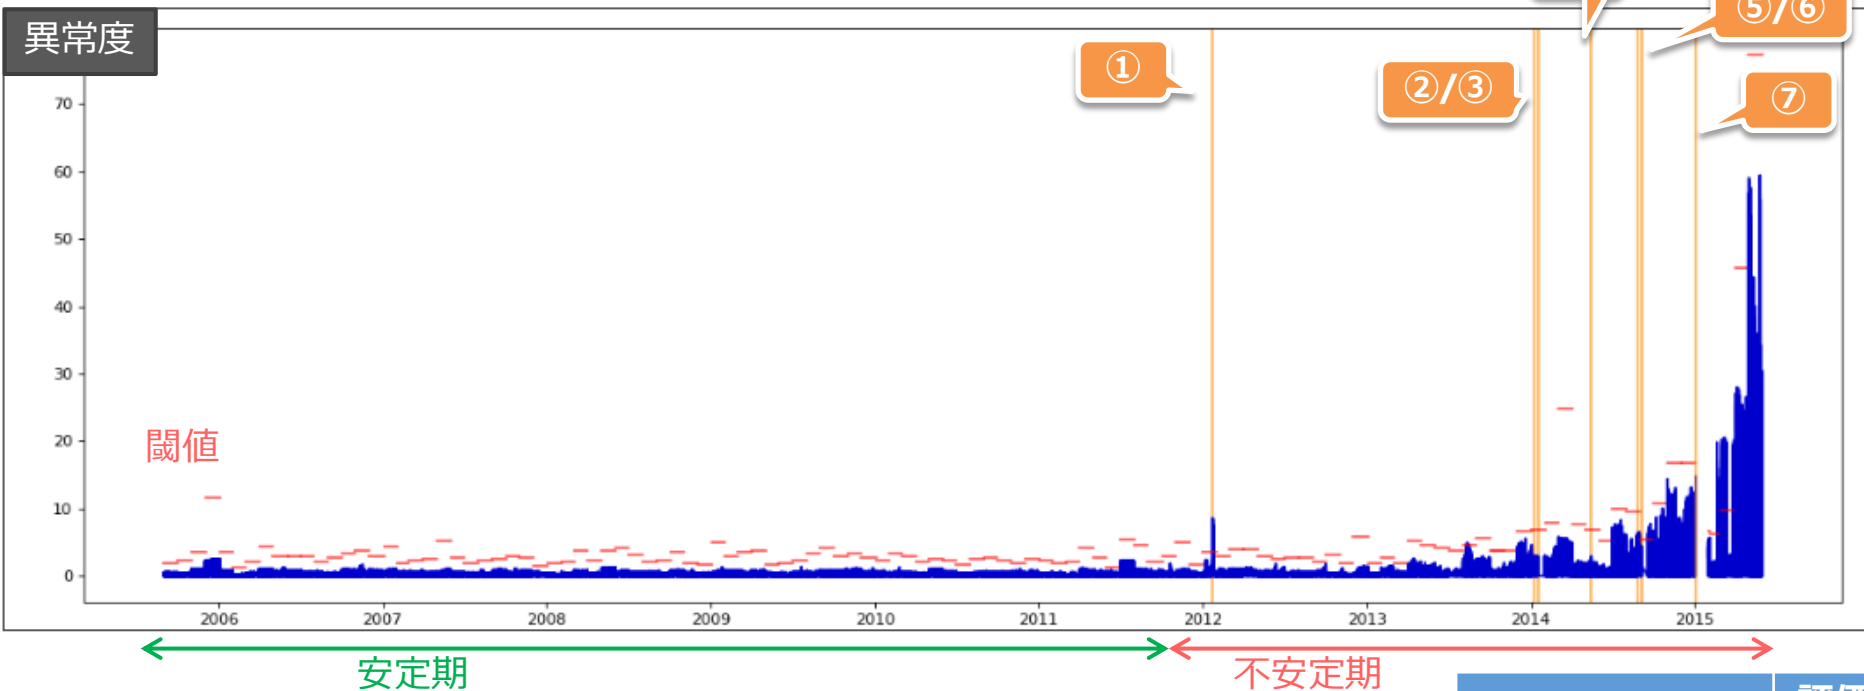
予測結果と実際の値の差(2乗誤差)を異常度とする



RNN実際の値(青)と予測値(橙)



# 機械学習を用いた故障の予兆検知 モデル構築 RNN 2/2



■ 直近1ヶ月(約60,000点)を学習して予兆検知


	評価
SAFEHOLD検出	1/7
安定期誤報	○
不安定期誤報	△
失報	×

	①	②	③	④	⑤	⑥	⑦
検出可能時間	1日10時間前	×	×	×	×	×	×

# 機械学習を用いた故障の予兆検知 モデル構築 AutoEncoder 1/2

## ■ AutoEncoder(自己符号化器)


- 圧縮することで特徴表現を獲得する
- 非線形の主成分分析を行うことが可能



## ■ 異常度の算出

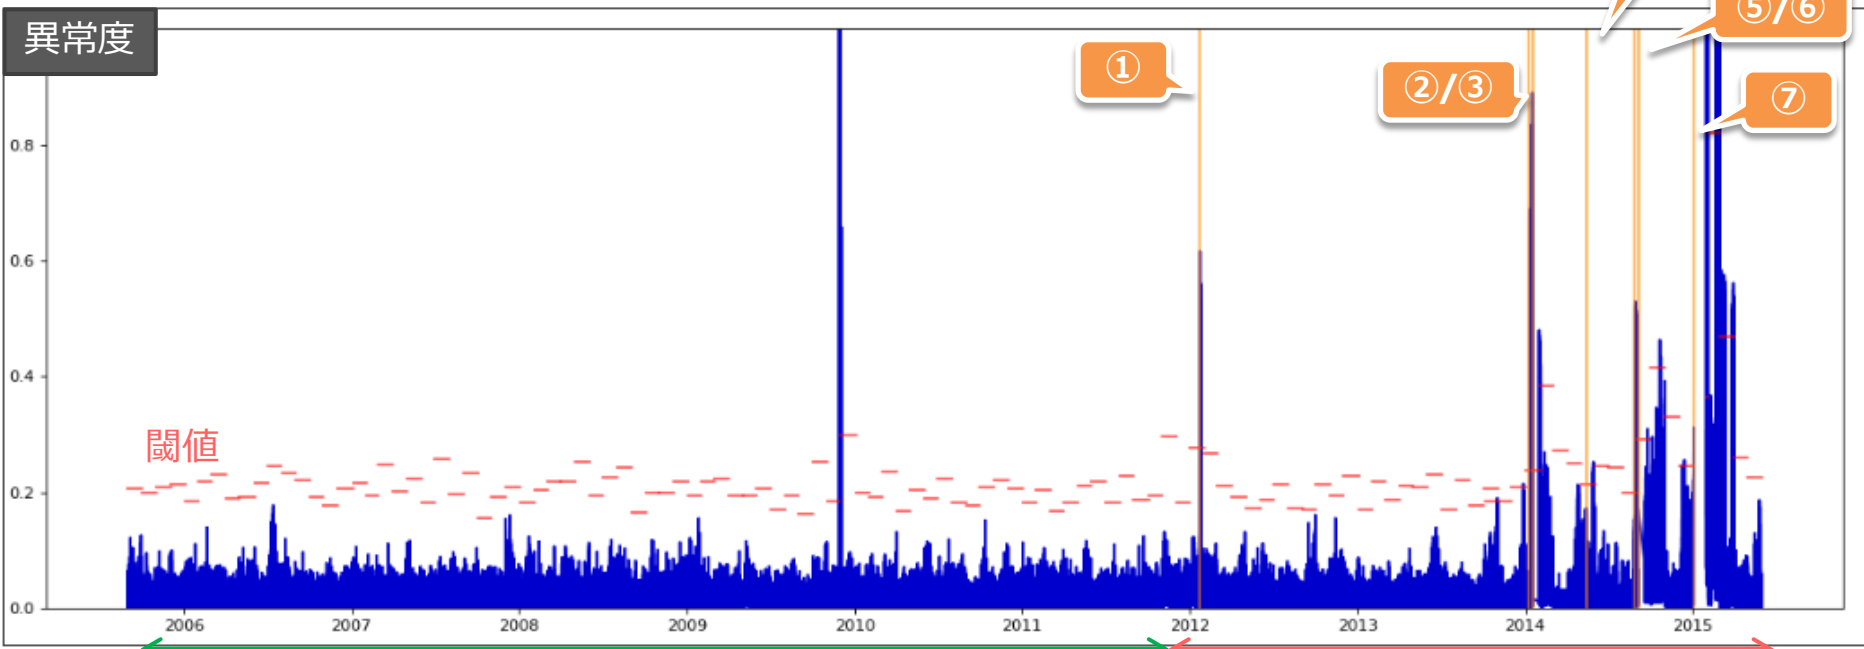
- 時間の連続値情報を捨て、点での情報を学習する
- 異常の場合は、正しく再構成できないと仮定

入力した結果と再構成した結果の差 (2乗誤差)の合計を異常度とする



AutoEncoder実際の値(青)と再構成(橙)

# 機械学習を用いた故障の予兆検知 モデル構築 AutoEncoder 2/2



■ 直近1ヶ月(約60,000点)を学習して予兆検知

	①	②	③	④	⑤	⑥	⑦
検出可能時間	1日2時間前	×	3日23時間前	×	×	3日21時間前	13時間前

	評価
SAFEHOLD検出	4/7
安定期誤報	○
不安定期誤報	△
失報	△

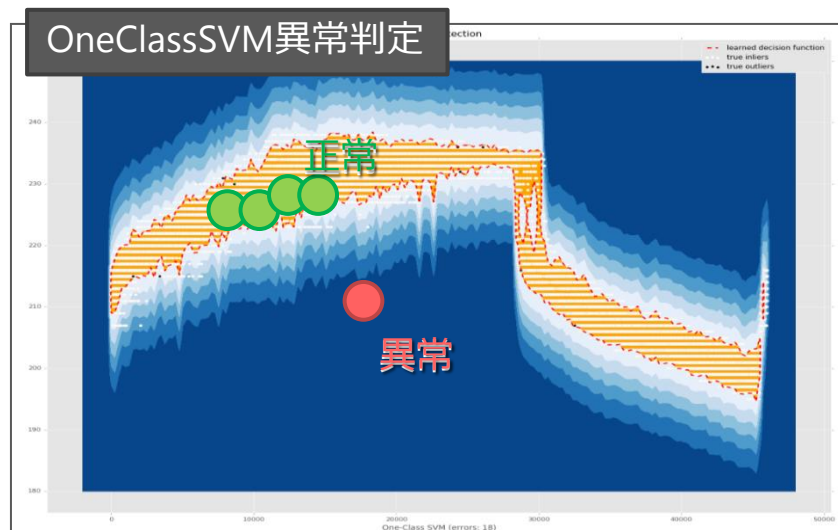
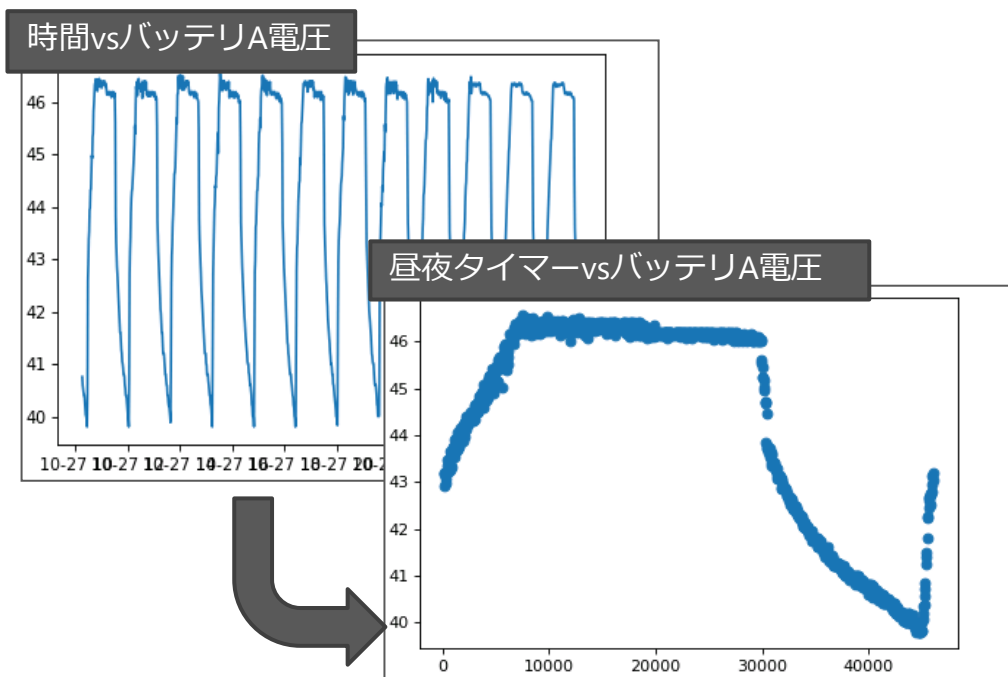
# 機械学習を用いた故障の予兆検知 モデル構築 OneClassSVM 1/2

## ■ OneClassSVM

- 境界によってクラスを分類するサポートベクターマシン(SVM)の1クラス版

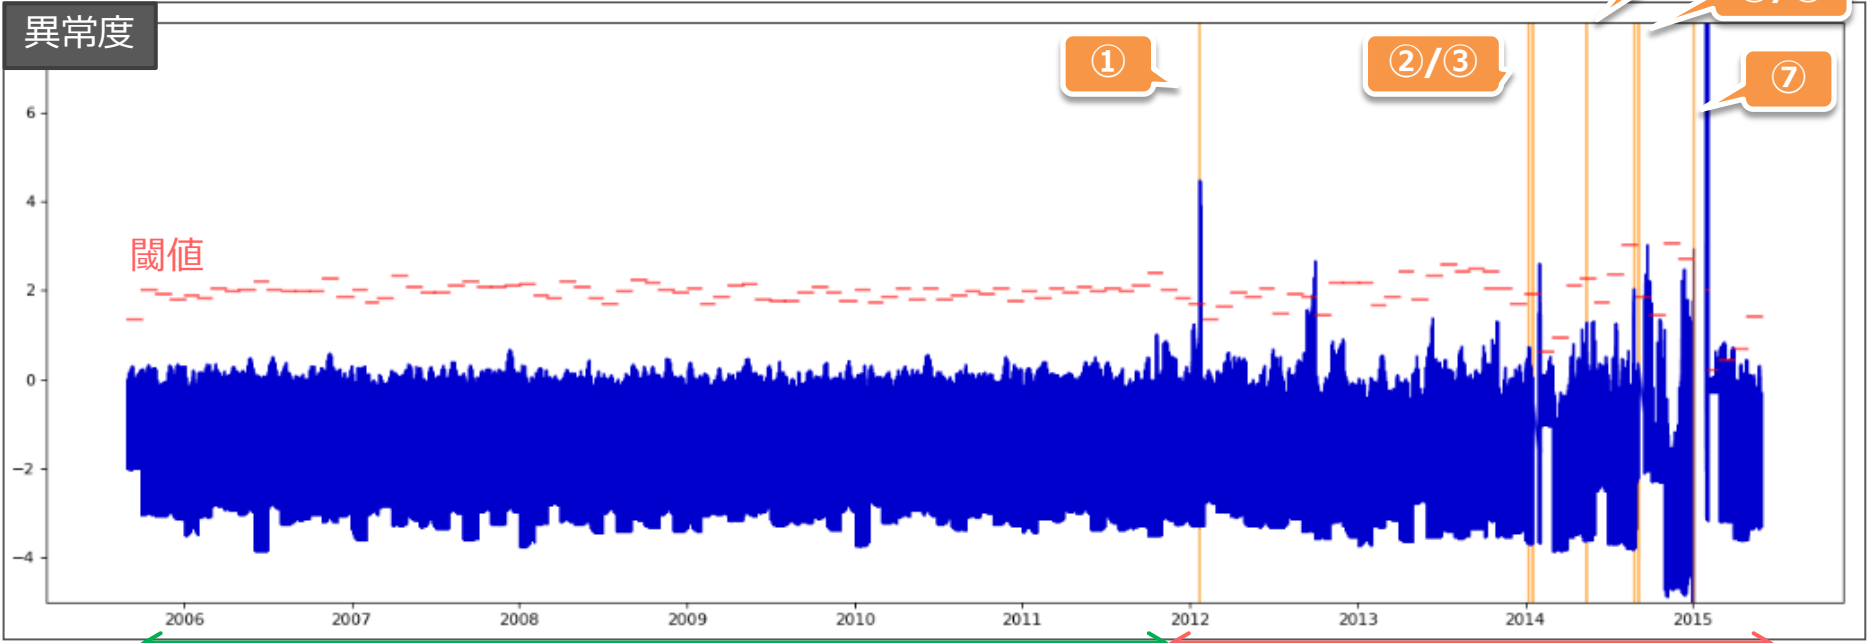
## ■ 異常度の算出

- 時間の連続値情報を捨て、1周期刻みのデータとし、学習する
- 異常の場合は、学習した境界外の離れた位置に存在すると仮定



境界からの距離を異常度とする

# 機械学習を用いた故障の予兆検知 モデル構築 OneClassSVM 2/2



■ 直近1ヶ月(約60,000点)を学習して予兆検知

	①	②	③	④	⑤	⑥	⑦
検出可能時間	1日11時間前	×	×	×	×	×	5時間前

	評価
SAFEHOLD検出	2/7
安定期誤報	○
不安定期誤報	△
失報	△

# 機械学習を用いた故障の予兆検知 モデル評価

- 不安定期の初回の異常①は1日以上前から検出可能
- ②以降は特に不安定となり、検出が難しくなっていると考えられる
- モデル調整で検出可能となる部分もあるが、誤報も増える  
実際の運用では、何日前に検知したいかも考慮する必要がある
- 手法により検知のしやすさが異なるため組み合わせることでより精度を上げることができている可能性がある

検出   安定期誤報   不安定期誤報   失報

各手法の検出可能時間

	①	②	③	④	⑤	⑥	⑦	検出	安定期誤報	不安定期誤報	失報
kNN	1日10時間前	×	3日23時間前	×	×	×	1日16時間前	3/7	△	△	△
RNN	1日10時間前	×	×	×	×	×	×	1/7	○	△	×
AutoEncoder	1日2時間前	×	3日23時間前	×	×	3日21時間前	13時間前	4/7	○	△	△
OneClassSVM	1日11時間前	×	×	×	×	×	5時間前	2/7	○	△	△

# まとめと今後の展開

## ■ まとめ

- 機械学習を用いて直近の正常データを学習させることにより、不安定期の初回の異常を1日以上前から検出することが可能である
- 最大3日前程度から検出可能であることを確認したモデルの調整次第でより早く検出することが可能となる

## ■ 今後

- 項目の組み合わせを再度検討し、現在検出できていない期間の異常検出を目標とする
- アンサンブルなど他の手法の検討
- 他の宇宙機への適用
- 運用で使用するためのプロトタイプ  
の作成

