





# 再使用ロケットエンジンの異常検知・診断に関する研究





○ 堤誠司, 佐藤大和, 尾亦範泰, 河津要  
JAXA/研究開発部門/第三研究ユニット(JEDIセンター)  
佐藤正喜, 橋本知之, 木村俊哉  
JAXA/研究開発部門/第四研究ユニット



1. 再使用ロケットエンジンPHM#と研究目的
2. モデルベース/データ駆動型シミュレーションを利用した学習データの生成
3. 二変量解析に基づくデータ駆動型異常検知手法
4. モデルベース/データ駆動を利用したセンサ最適化手法の開発
5. 今後の予定

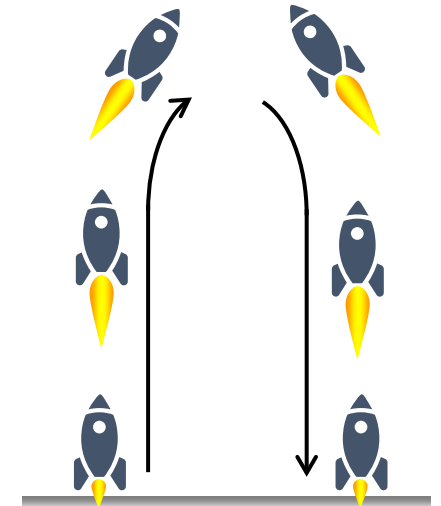
#Prognostics and Health Management

# 1. 再使用ロケット開発におけるキー技術



整備

- 再使用ロケット運用コストの鍵
- 支配要因はエンジン  
(取り外し/分解点検/再取り付け)



エンジン再整備コスト低減に向けた4つのキー技術# :

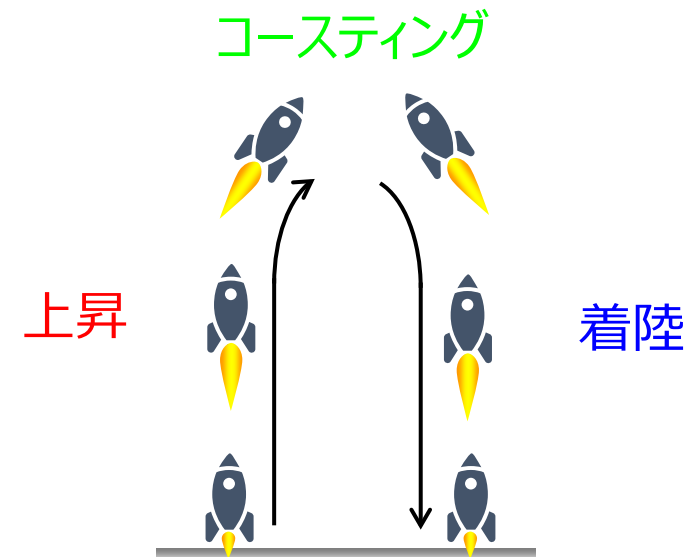

1. 長寿命化設計技術
2. 予寿命評価技術
3. 非破壊検査技術
4. 故障予知・診断技術(PHM)

#橋本ら  
JSASS-2016-4351

!! リアルタイムの異常検知・診断は対象外 !!

# 1. 液体ロケットエンジンにおけるPHMの課題

1. データが少ない。特に，異常データ。
2. センサ故障/システム故障の識別。
3. 定常だけではなく，起動/停止過渡状態，制御入力により状態が変化。
4. エンジン個体差，作動点ドリフト。
5. 故障予知・診断に対して現状のセンサ配置・点数の最適化
6. センサ計測値と実現象の乖離。



# 1. アプローチ: モデルベース/データ駆動

## モデルベース:

- **第一原理シミュレーション**を利用. 利用できるのであれば使った方が絶対に良い.
- システムを対象とするため, **マルチモーダル**(マルチフィジックス)の現象が対象.
- 一般的に, 設計で利用するよりも厳しい予測精度が求められる. モノのバラつき, 使用する環境に起因したバラつきまでを考慮する必要がある.
- 必要要件:
  1. モデルの持つ**不確定性の定量評価**. (Uncertainty Quantification, UQ#)
  2. **予測精度**の検証 (Validation and Verification, V&V)

## データ駆動:

- **データから特徴量(パートン)**を抽出して利用.
- 第一原理シミュレーションが利用できない場合の最終手段(!?)
- 私が知る限り, V&VやUQの手法はまだ確立していない.

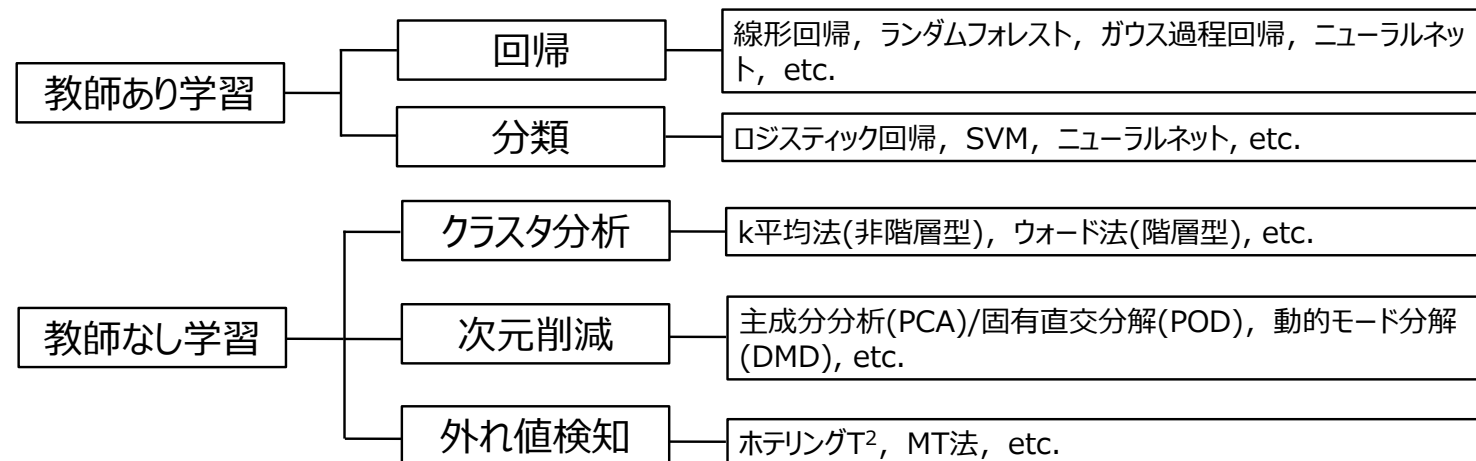
# 1. アプローチ: 教師有り/教師無し

## 教師有り:

- データにラベル付けをして学習させる。 **既知の事象を対象**とする。
- 対象システムの正常・異常データが十分ある場合は利用可能。
- ディープラーニングに代表される近年の機械学習はこちら。

## 教師無し:

- データを前処理して特徴量を抽出。得られた特徴量からモデルを作成する。
- **未知の事象が対象**。
- 教師有りと比べると少ないデータ量で学習できるが、特徴量の抽出が鍵。



これら以外に強化学習もある。

# 1. 液体ロケットエンジンにおけるPHMの課題

1. データが少ない。特に，異常データ。

⇒ モデルベース/データ駆動型シミュレーションを利用した学習データの生成。

2. センサ故障/システム故障の識別。

3. 定常だけではなく，起動/停止過渡状態，制御入力により状態が変化。



4. エンジン個体差，作動点ドリフト。

⇒ 二変量解析に基づくデータ駆動型異常検知手法の開発

5. 故障予知・診断に対して現状のセンサ配置・点数の最適化


⇒ モデルベース/データ駆動を利用した最適化手法の開発

# 1. RSRエンジン







推進薬	LOX/LH2
サイクル	エキスパンダーブリード
ノミナル推力 (Isp)	40kN (320 sec)
スロットリング	40~100%
燃焼圧	3.4MPa
混合比	6.0
再着火可能	





# 1. 目的と発表内容

- 目的：再使用ロケット実現に向けて必須のPHM技術を獲得する。
- 発表内容：RSRエンジン地上燃焼試験(地燃)データを使った研究を紹介する。
  1. モデルベース/データ駆動型シミュレーションを利用した学習データの生成
  2. 二変量解析に基づくデータ駆動型異常検知手法の開発
  3. モデルベース/データ駆動を利用したセンサ最適化手法の開発



RSRエンジン地燃

再使用ロケット実験機(RV-X)


CALLISTO実験機

再使用ロケット

1. 再使用ロケットエンジンPHMと研究目的
2. モデルベース/データ駆動型シミュレーションを利用した学習データの生成
3. 二変量解析に基づくデータ駆動型異常検知手法
4. モデルベース/データ駆動を利用したセンサ最適化手法の開発
5. 今後の予定

## 2. シミュレーションの利用

1. データが少ない. 特に, 異常データ.
2. センサ故障/システム故障の識別.
3. 定常だけではなく, 起動/停止過渡状態, 制御入力により状態が変化.
4. エンジン個体差, 作動点ドリフト.
5. 故障予知・診断に対して現状のセンサ配置・点数の最適化
6. センサ計測値と実現象の乖離.



ないなら作る!


⇒ モデルベース/データ駆動型シミュレーションを利用した学習データの生成<sup>#1,2</sup>

#1 Sato D. et al, Acta Astronautica 2020. doi: 10.1016/j.actaastro.2020.07.037


#2 Sato D., Annual Conf. of the PHM Society 2020. doi:10.36001/phmconf.2020.v12i1.1134

## 2. モデルベース: System Level Simulator

- システムレベルシミュレーション(SLS)を利用し, 起動過渡を含むロケットエンジンの内部熱流動をモデル化.
- SLSは1次元物理モデルから構成される.



RSR engine



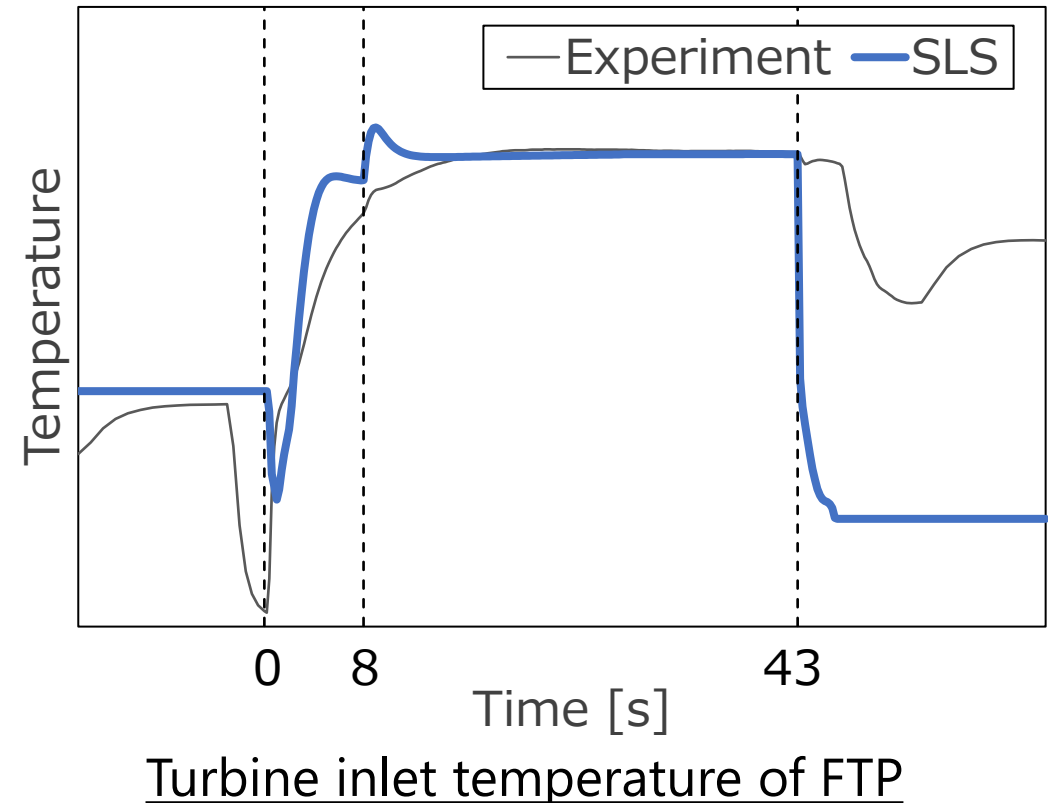
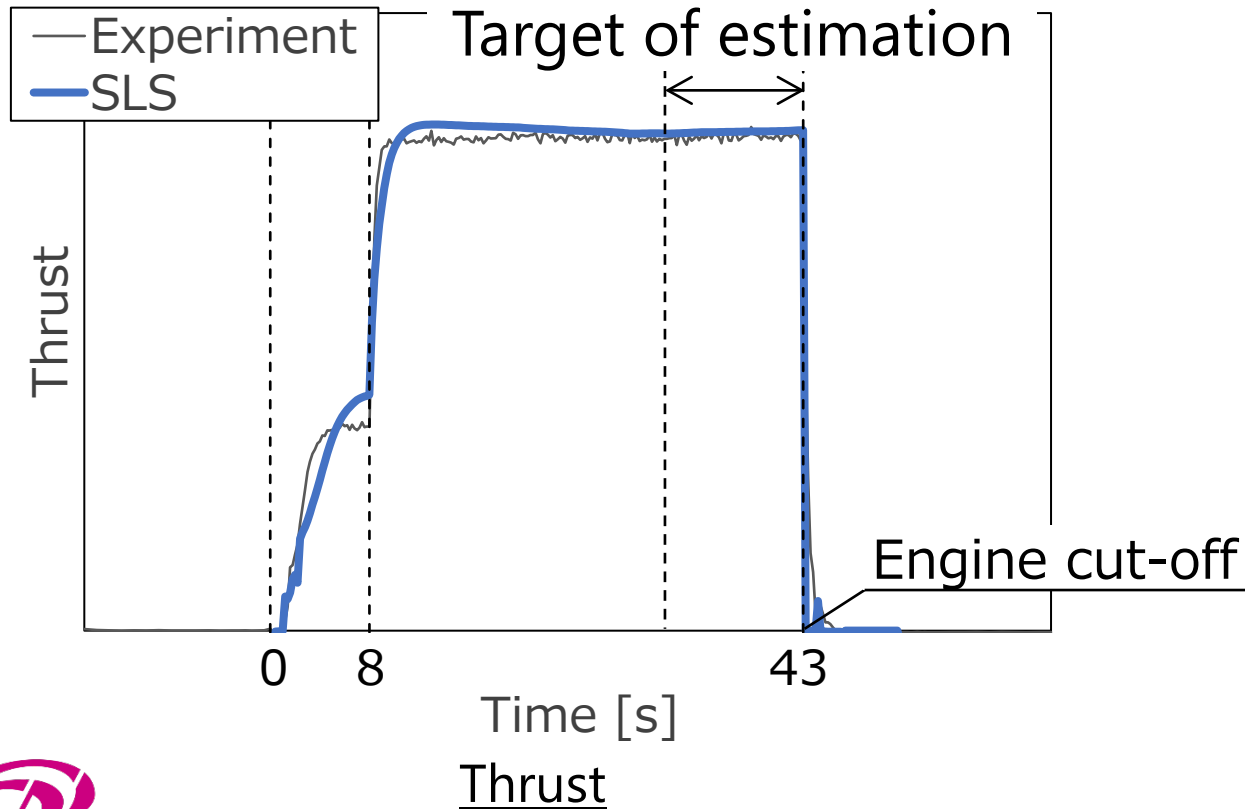
Each component has model parameter(s).

RSR engine model

- SLS全体で30程度のモデルパラメータがある。(1次元物理モデルだから)
- データ同化の1つであるアンサンブルカルマンフィルタ(EnKF)を使い, モデルパラメータを同定した.

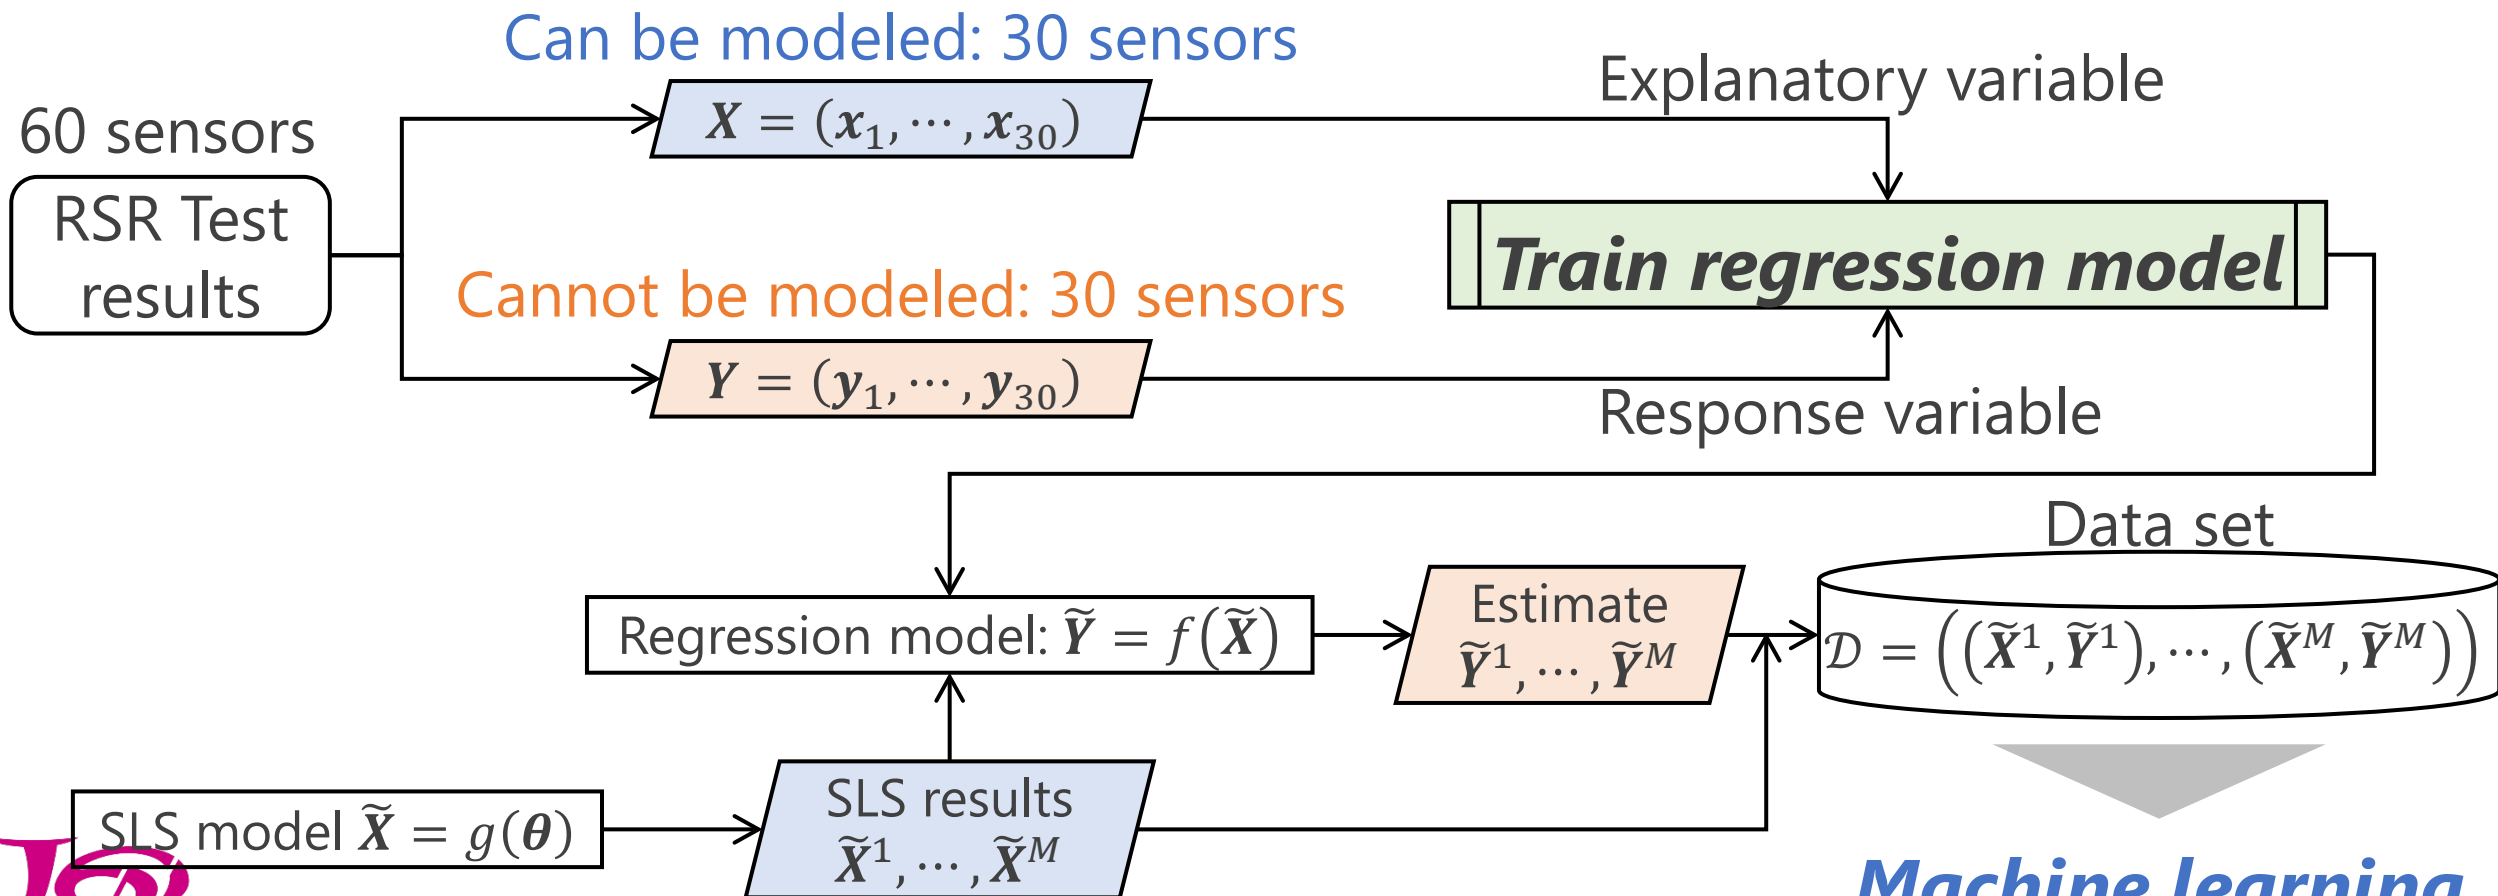
## 2.モデルベース: System Level Simulator

- RSR地燃データで検証.
- ここでは定常作動点を対象にデータ同化を行い, **2.3%程度の精度**で予測可能
- 必ずしもすべてのセンサでよい一致が得られているわけではない. (熱に関連する現象の予測が難しい.)



## 2. データ駆動：第一原理でモデル化できないセンサ

- 第一原理モデルではモデル化できないセンサもあり. ex. 軸受
- モデル化できるセンサ  $X$  を説明変数, モデル化できないセンサ  $Y$  を目的変数とした回帰モデル(データ駆動)を作成する.



## 2. データ駆動: GMMクラスタリング回帰

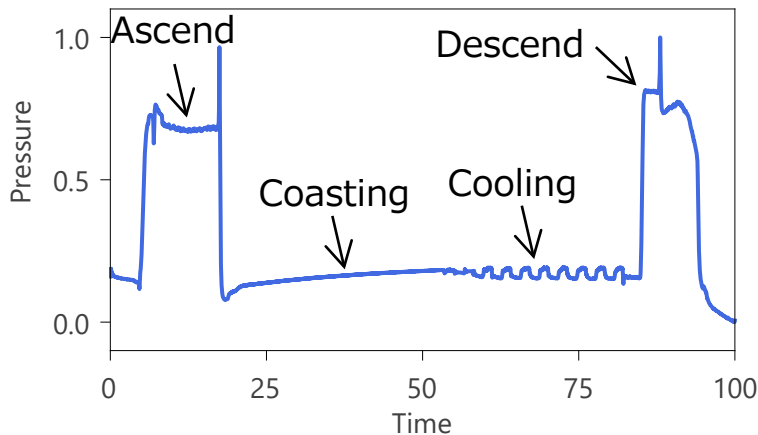
Exploratory variables: Sensors modeled in SLS

Regression:  $y = g(x)$

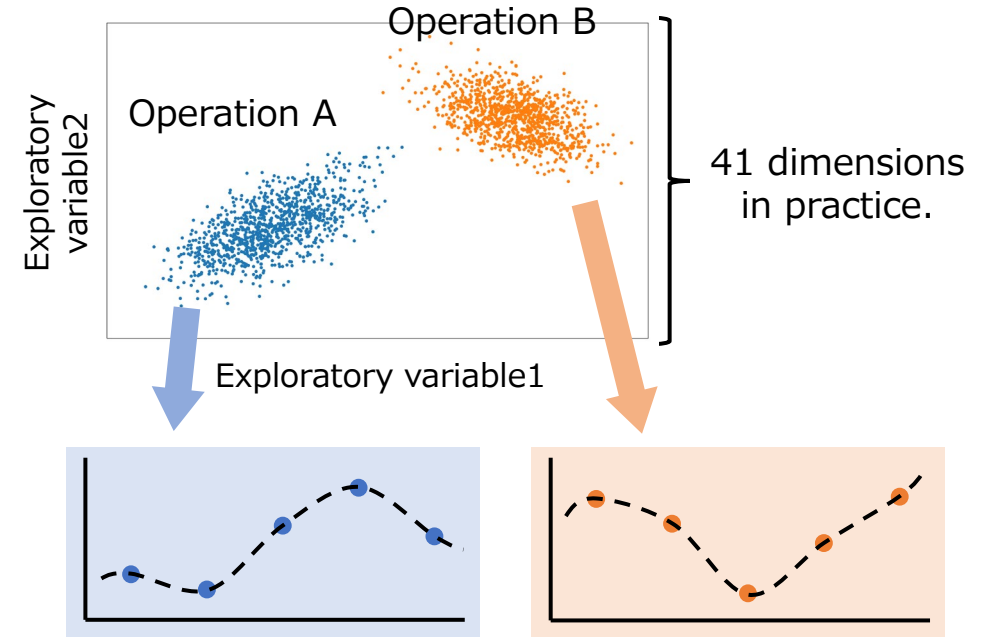
Objective variables:  
Sensors unmodeled in SLS

Various operating conditions appear in one flight.

⇒ Engine condition is different



Operating condition is automatically classified using **Gaussian Mixture Model**.



Generate a regression model separately for each operating condition using **Ridge regression**


RSR地燃データで検証.



## 2. データ駆動: GMMクラスタリング回帰

Pressure sensor  
Exploratory variables: enough  
Physics: simple


Sufficient accuracy



Colors: operating condition classified by GMM

Temperature sensor  
Exploratory variables: limited  
Physics: complicated

Poor accuracy




- ❑ 物理現象がシンプルで、説明変数が十分にある現象では十分な予測精度が得られる。
- ❑ 非線形性の強い複雑物理現象(説明変数がたくさん必要)では、予測精度には問題あり。(特に温度センサー)

1. 再使用ロケットエンジンPHMと研究目的
2. モデルベース/データ駆動型シミュレーションを利用した学習データの生成
3. 二変量解析に基づくデータ駆動型異常検知手法
4. モデルベース/データ駆動を利用したセンサ最適化手法の開発
5. 今後の予定

## 3. Aim of Proposed Data-Driven Methodology

1. データが少ない. 特に, 異常データ.
2. センサ故障/システム故障の識別.
3. 定常だけではなく, 起動/停止過渡状態, 制御入力により状態が変化.
4. エンジン個体差, 作動点ドリフト.
5. 故障予知・診断に対して現状のセンサ配置・点数の最適化
6. センサ計測値と実現象の乖離.



単変量を見ているだけではセンサ故障とシステム故障の識別は難しい.

⇒ 二変量のデータ駆動型解析#

### 3. Identification of Sensor/System Failure

- ❑ Using bivariate time-series analysis, relationships between two sensors are visualized in a **Sensor-state Estimation Matrix (SEM)**.
- ❑ **Sensor failure** → Fault signal appears in **a band-like elements**.
- ❑ **System failure** → Fault signal appears in **distributed elements**.
- ❑ **Sensor/system failure can be identified from the appearance of fault signal in SEM.**

	A	B	C	D	E	F
A						
B	×					
C	○	×				
D	○	×	○			
E	○	×	○	○		
F	○	×	○	○	○	

In case of sensor B failure


	A	B	C	D	E	F
A						
B	○					
C	○	○				
D	○	×	×			
E	○	×	×	×		
F	○	○	○	○	○	

In case of a system failure

○ normal
× abnormal

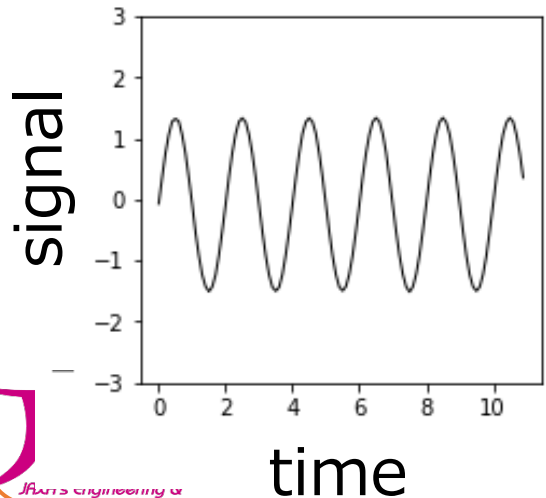
# 3. Generation of Phase Plane Trajectory

Sensor  $s_i$ :  $\mathcal{D}^{s_i} = [x_1^{s_i}, \dots, x_T^{s_i}]$




1. Standardization  $\tilde{\mathcal{D}}^{s_i}$
2. Apply sliding window  $\tilde{\mathcal{D}}_{win}^{s_i}$
3. Apply PCA
4. Principal component score of  $m^{th}$  mode  $\mathbf{Y}^{s_i(m)}$

Sensor  $s_j$ :  $\mathcal{D}^{s_j} = [x_1^{s_j}, \dots, x_T^{s_j}]$



- 1-3. Same
4. Principal component score of  $m^{th}$  mode  $\mathbf{Y}^{s_j(m)}$


## Phase Plane Trajectory



$$\mathcal{O}^{(m)}(s_i, s_j) = [\mathbf{Y}^{s_i(m)}, \mathbf{Y}^{s_j(m)}]$$

### 3. Degree of Dissimilarity


Normal:  $O_{Normal}^{(m)}(s_i, s_j)$



Dynamic Time Warping (DTW)

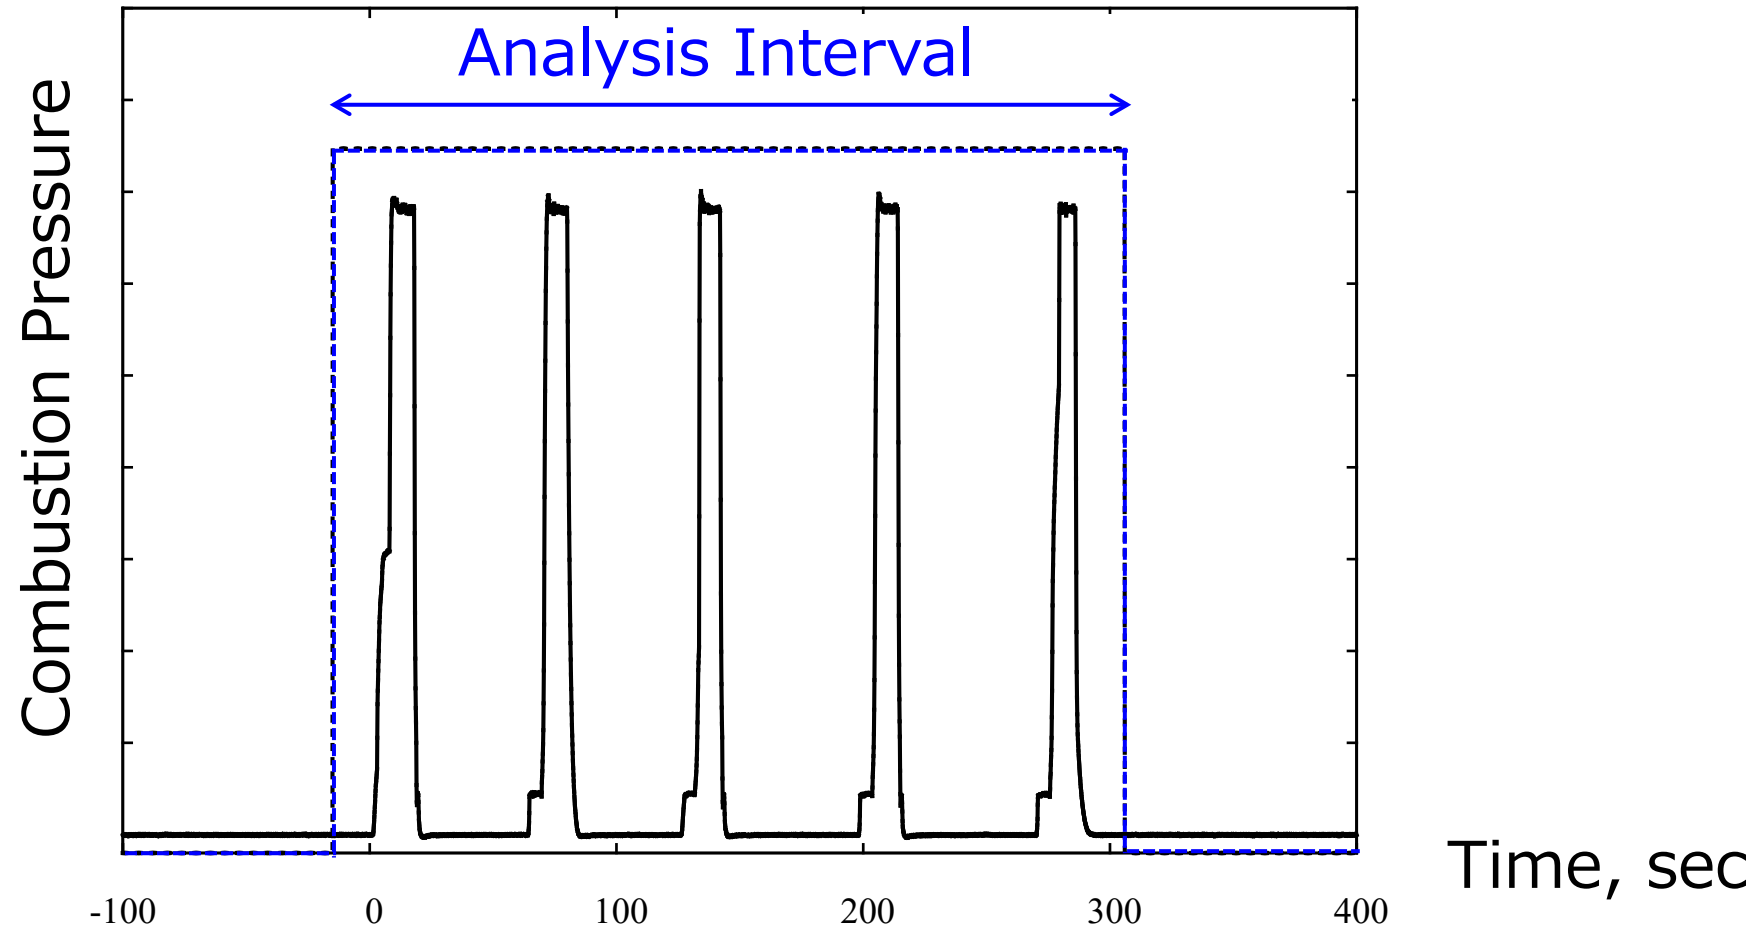
$G_{s_i, s_j}^{(m)}(Normal, Anomaly)$

Anomaly:  $O_{Anomaly}^{(m)}(s_i, s_j)$




- ❑ Challenges in liquid-propellant rocket engines
  3. Dynamic change of engine operating conditions.
  4. Individual differences, drift of operating conditions.
- ❑ DTW is expected to evaluate the degree of dissimilarity with robustness.
- ❑ Anomaly detection is conducted using Hotelling T2 theory.

# 3. Static-Firing Test




- No. of Tests : 19 (Run001-019, nominal( $R_0$ ): Run018)
- No. of Sensors : 59

# 3. Results of Sensor-state Estimation Matrix (SEM)



PCA Mode 1




PCA Mode 2

Threshold of  $\alpha = 99.5\%$


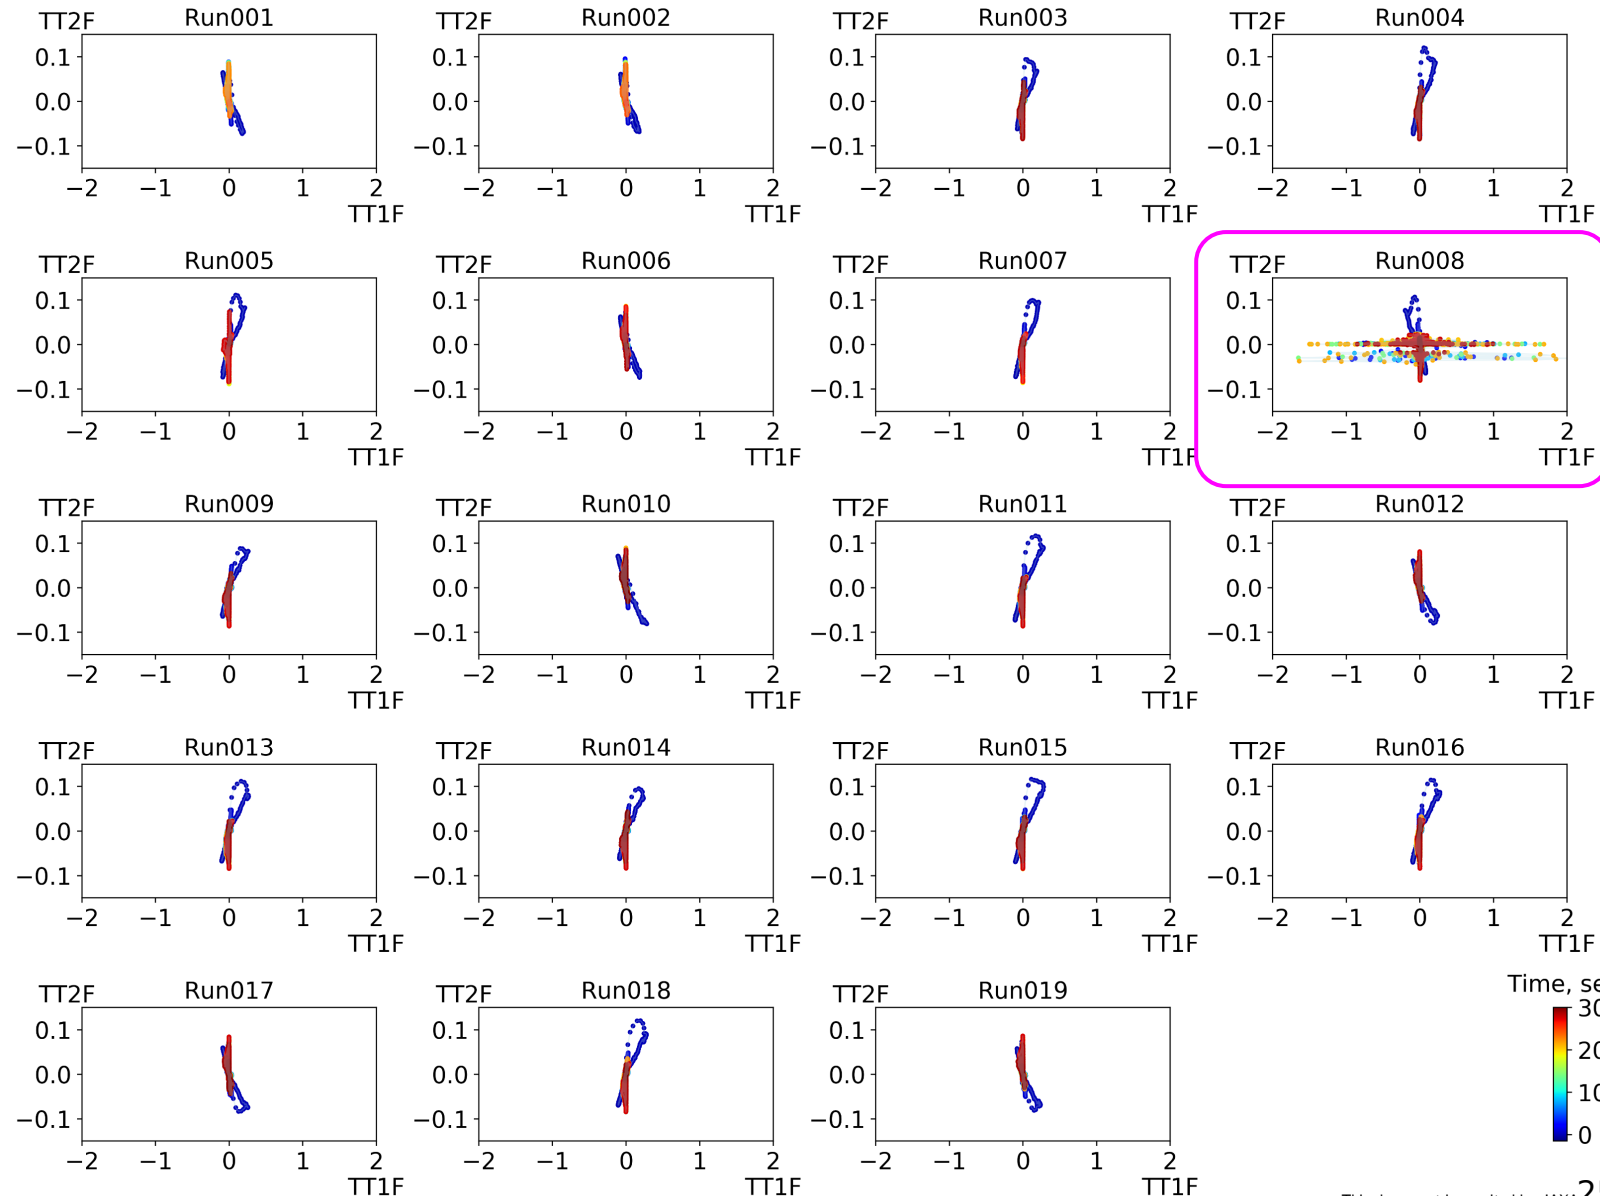
- PCA Mode1: dominant feature of the time-series data
- PCA Higher modes: additional feature of the data (high freq. components)
- Run008, Run015 → band-like elements → sensor failure?
- Run005, Run019 → distributed elements → system failure?



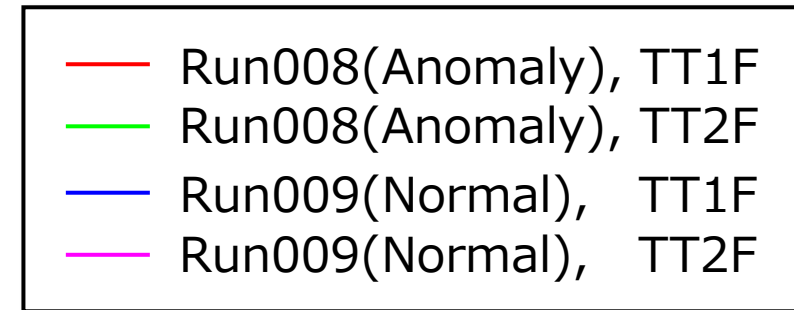

# 4. (Run008) TT1F-TT2F Phase Plane Trajectories



TJM2F1			005				
TJM2F2			005				
TT1F	008	008	008	008	008	008	00
TT2F				005			
TCIGO					005		
TCIGF							



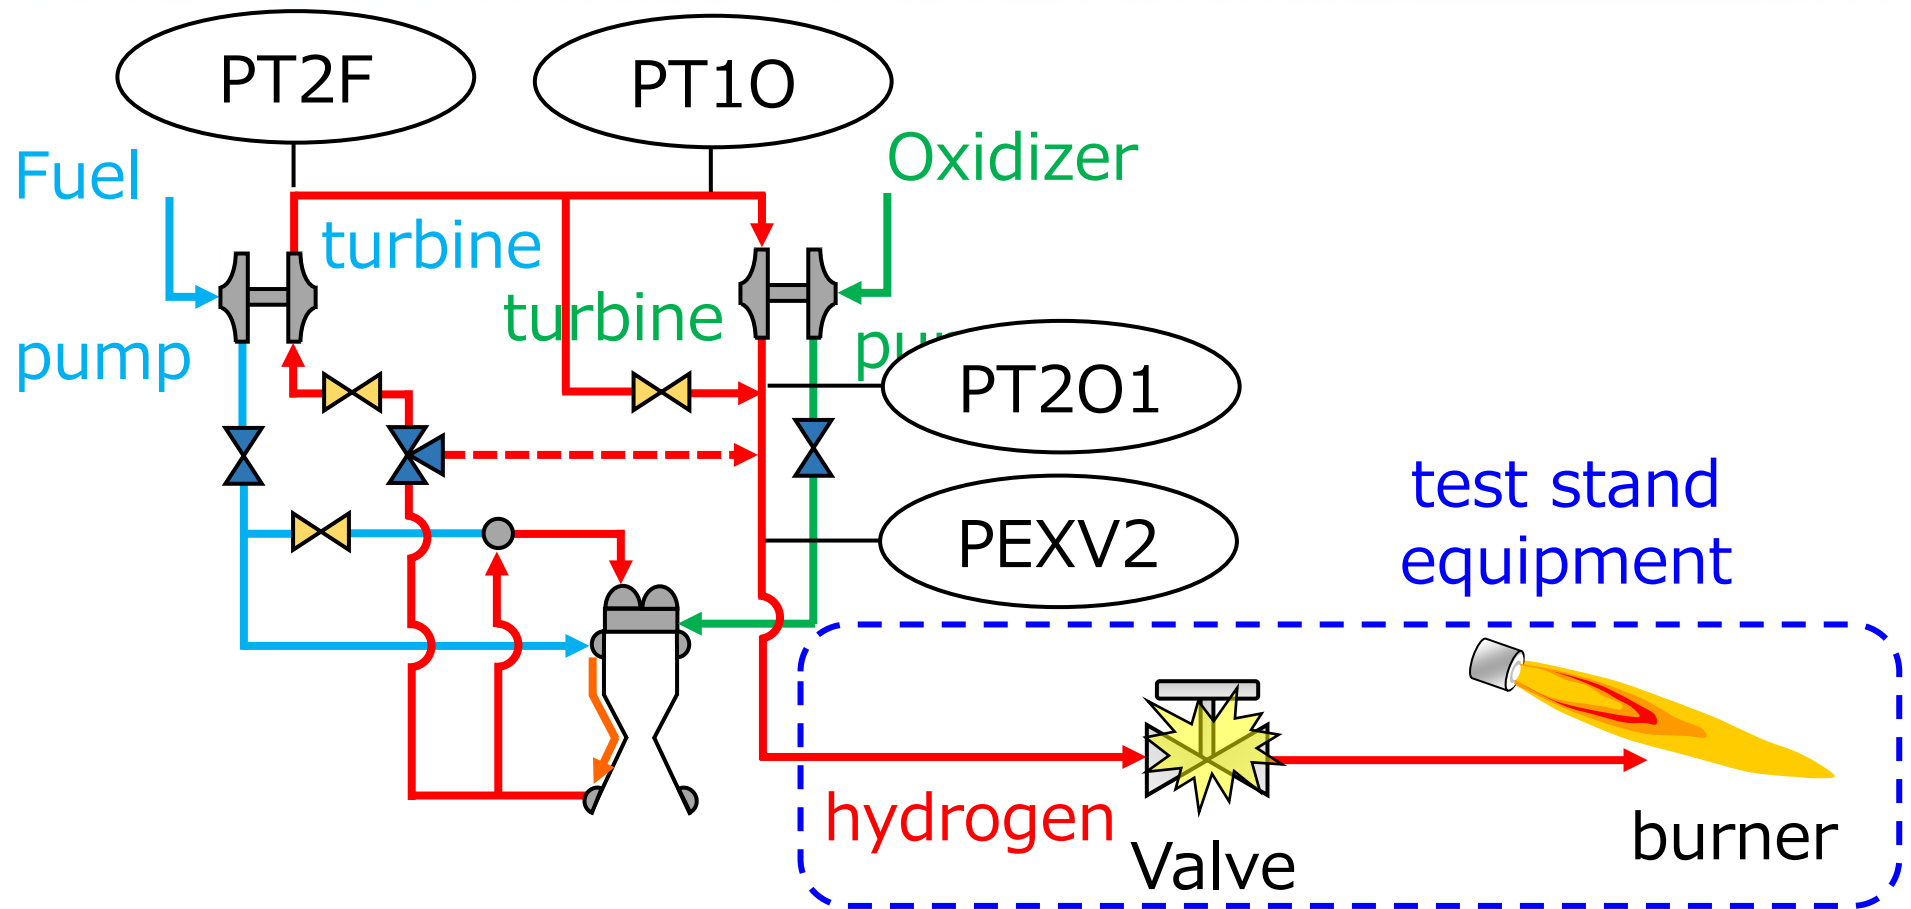
### 3. (Run008) TT1F Sensor Failure



- ❑ A sheathed thermocouple installed at the inlet of the fuel turbine (TT1F) was partially broken. → High freq. vibration
- ❑ Sensor failure is successfully detected at PCA mode 2, even in the dynamic change of the engine operation, and deviation between static firing tests.



### 3. (Run005) System Failure at Valve Operation




- ❑ In the static-firing test, hot hydrogen gas after driving the turbines was burned for safety.
- ❑ A failure related to the valve operation occurred. → System failure
- ❑ System failure is successfully detected.

1. データ駆動型の二変量時系列解析による故障予知手法を開発．RSRエンジン地燃データを利用して実証した．
2. エンジン作動シーケンスの動的な変化や試験間の誤差(system variation)があっても，19試験の中で発生したセンサ/システム故障を識別して検知することができた．
  - タービン入口温度のセンサ故障．
  - 試験設備のバルブに起因したシステム異常．

1. 再使用ロケットエンジンPHMと研究目的
2. モデルベース/データ駆動型シミュレーションを利用した学習データの生成
3. 二変量解析に基づくデータ駆動型異常検知手法
4. モデルベース/データ駆動を利用したセンサ最適化手法の開発
5. 今後の予定

## 4. センサ配置の最適化と故障診断

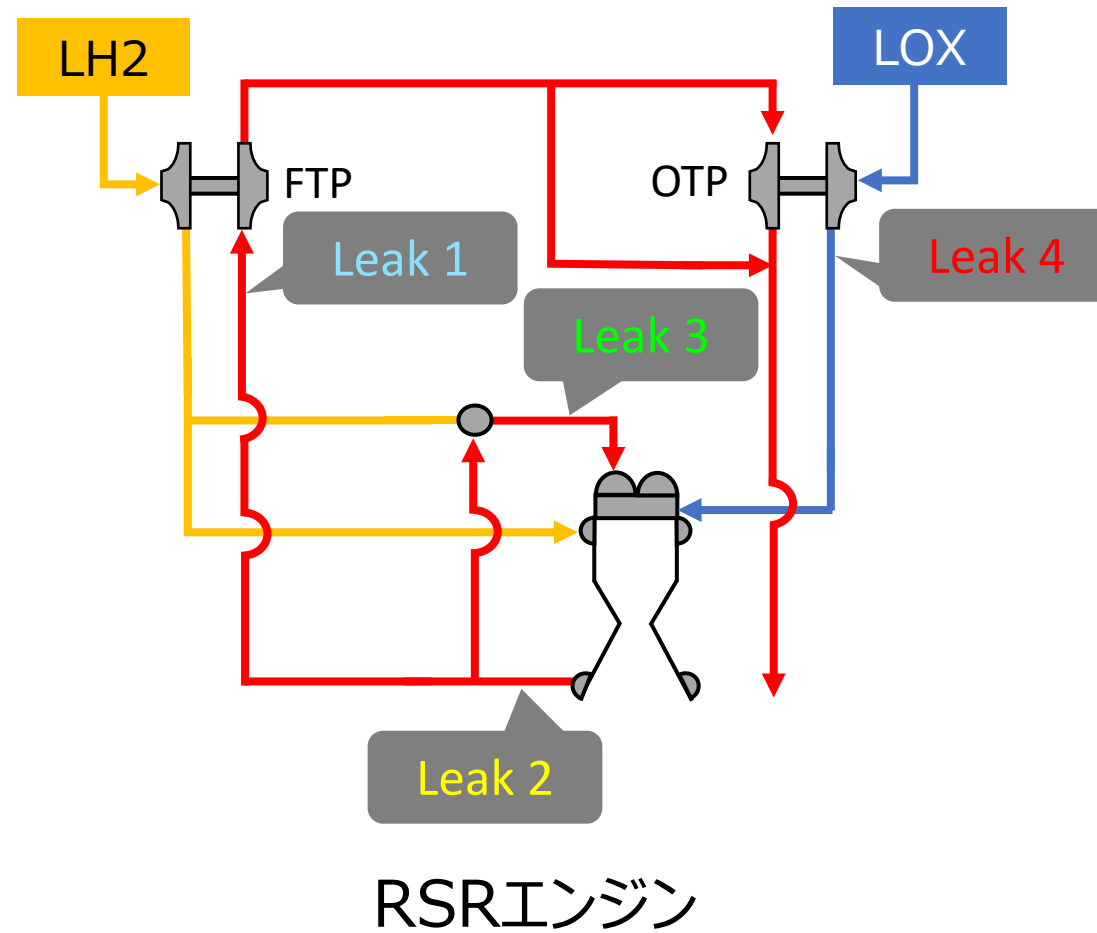
1. データが少ない. 特に, 異常データ.
2. センサ故障/システム故障の識別.
3. 定常だけではなく, 起動/停止過渡状態, 制御入力により状態が変化.
4. エンジン個体差, 作動点ドリフト.
5. 故障予知・診断に対して現状のセンサ配置・点数の最適化
6. センサ計測値と実現象の乖離.



先行研究が少ないので, まずは水素漏洩を対象にやってみた.  
⇒ モデルベース/データ駆動のハイブリッド# (全部乗せ?)


## 4. 水素漏洩の検知・診断

- 液酸液水を燃料とするロケットエンジンのメンテナンス作業の中で、極低温水素の漏洩対策が最も大きな工数を占める。
- SLSを使ったモンテカルロ解析とデータ駆動型の教師有り機械学習を使い、センサ最適化、及び漏洩箇所の特特定(診断)を可能とする手法を開発する。





# 4. SLSによる水素漏洩データ生成


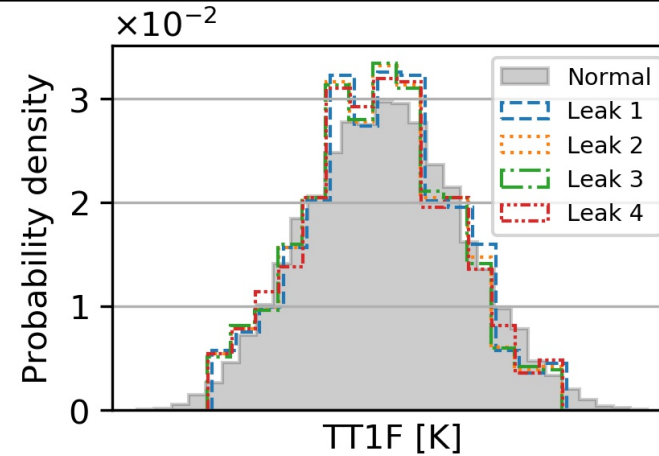



黒点: experiment  
 黒線: 正常(ノミナル)  
 灰色線: 正常分布  
 カラー: 異常データ(ノミナル)

SLSのモデルパラメータにばらつきを与え、正常データ、異常データ(漏洩4カ所)をモンテカルロ的に生成した。

正常ケースと同様に，漏洩しているときのセンサ値もばらつく  
 レッドライン(閾値)判定では正常と漏洩の判別は不可


シミュレーション終了 (t=128秒) 時のセンサ値  $x = (x_1, x_2, \dots, x_n)$  の分布



多変量を利用した  
 機械学習によって解決する

## 4. 多変量解析のコンセプト

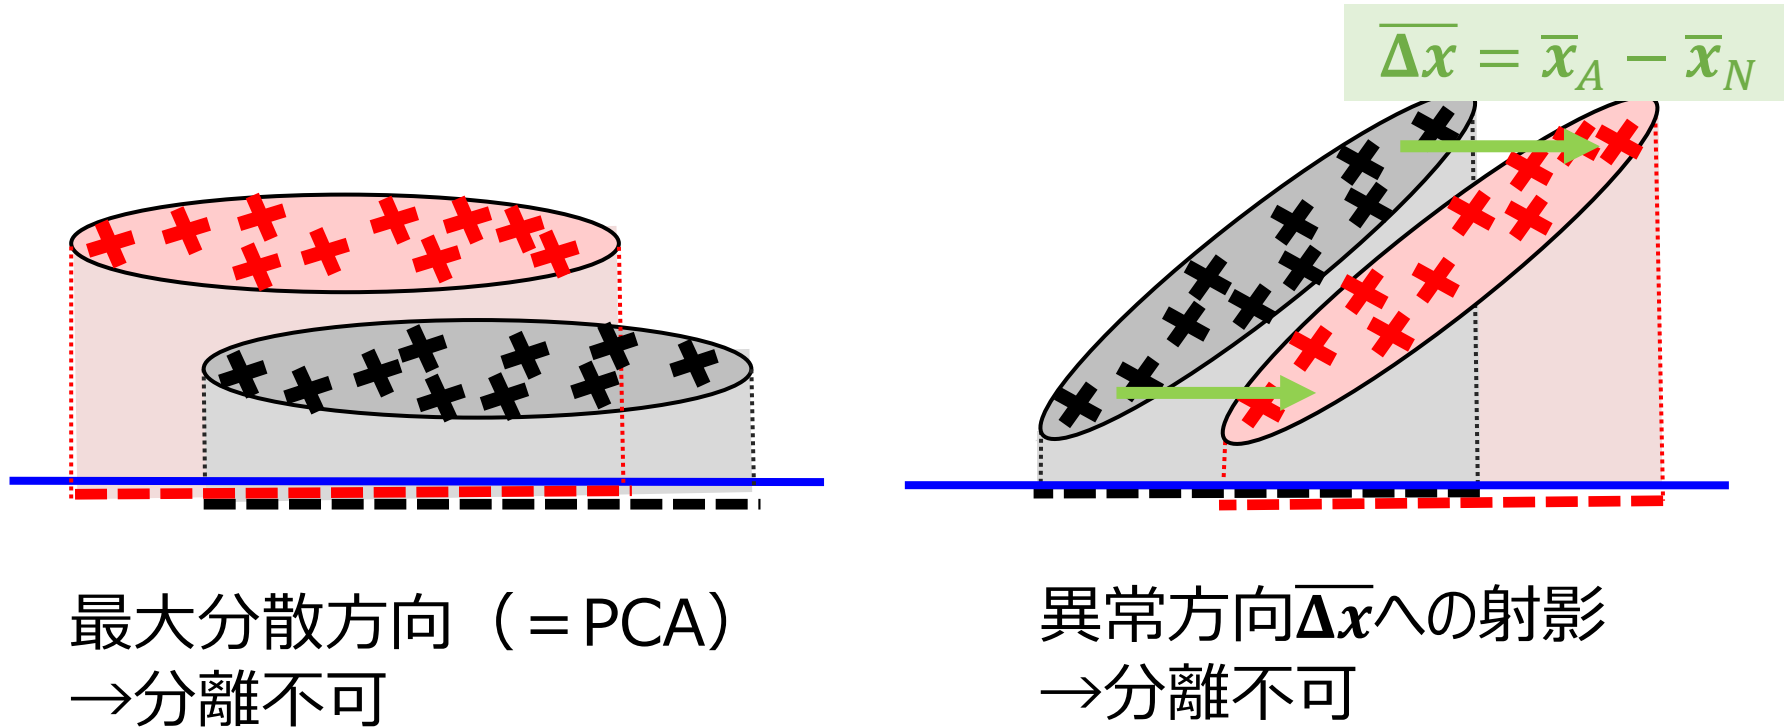
### 2 センサの場合



正常と異常は一見区別できそうだが、**単独のセンサ値のみではオーバーラップしているので検知不可**

⇒ **多数のセンサを組み合わせた指標**が必要である

## 4. 多変量を使った正常/異常判別法の検討



主成分分析や, 異常時の変化 $\overline{\Delta x}$ への単純な射影では不可

## 4. 多変量を使った正常/異常判別法の検討

### 分離可能な指標の導出法：

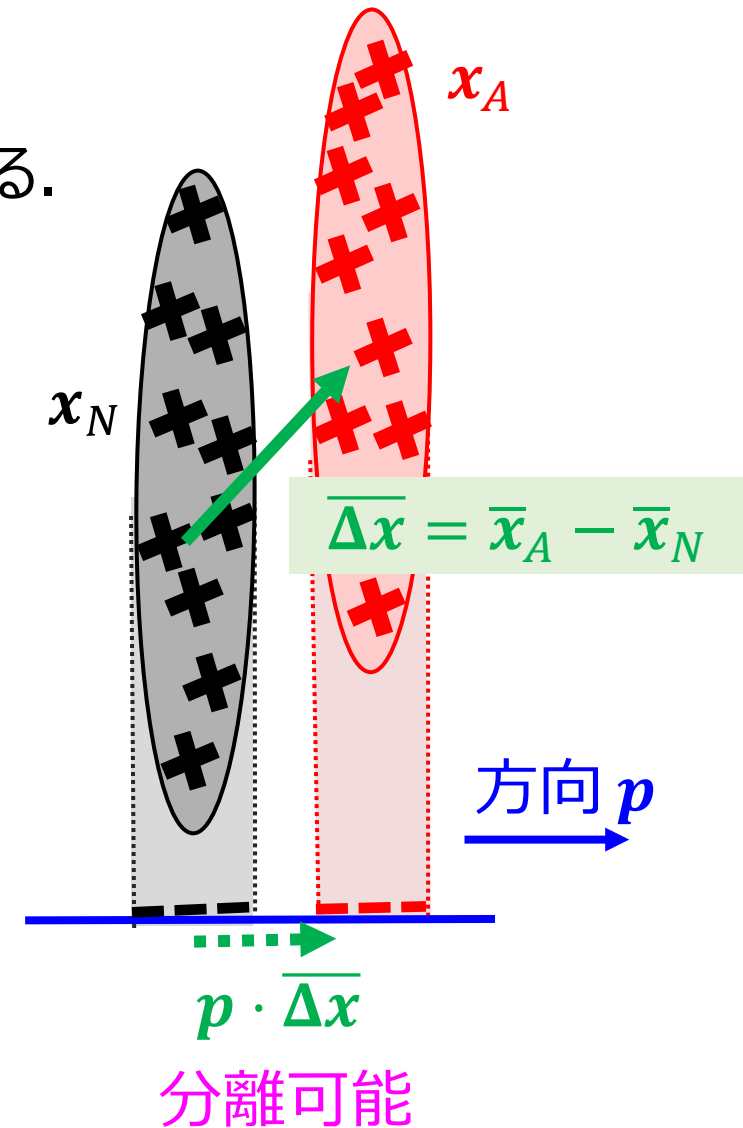
方向  $\rightarrow$  に射影したときの、  
データの分布  $\cdots$  は小さく，異常時の変動  $\cdots \rightarrow$  は大きくする。

$$\operatorname{argmax}_p \frac{(\mathbf{p} \cdot \overline{\Delta \mathbf{x}})^2}{\Sigma(\mathbf{p} \cdot \mathbf{x}_N)^2} \cdots \rightarrow$$

□ 最適化は解析的に解ける。


$$\mathbf{p} \propto \Sigma_N^{-1} \overline{\Delta \mathbf{x}}$$

□ Fisherの線形判別法(クラス内とクラス間の分散の比を最大化)と数学的にほぼ同値。




## 4. 多変量を使った判別結果

線形判別分析による，異常スコアのヒストグラム



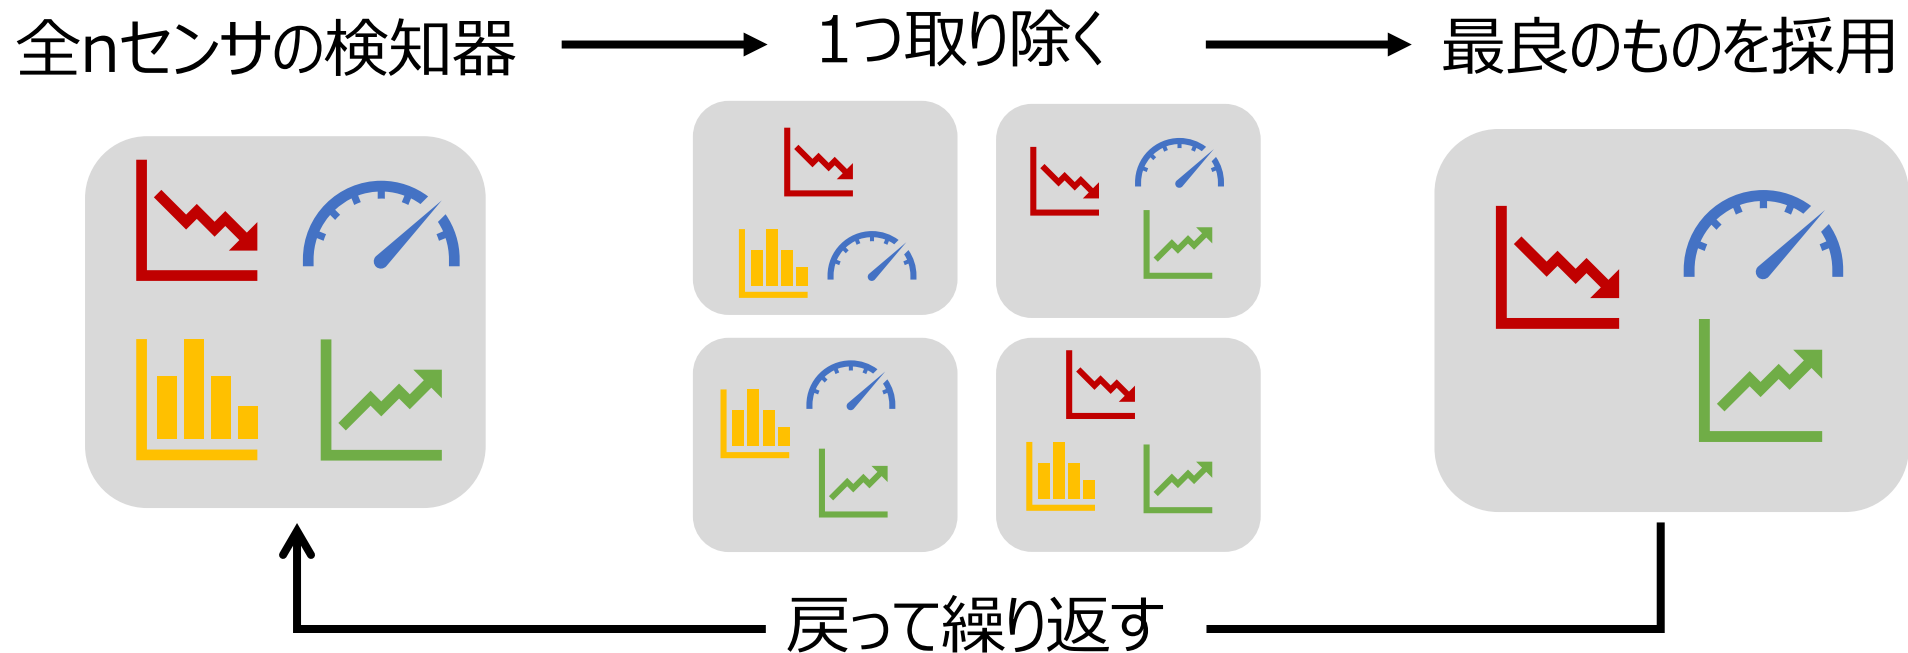
Ref. 単変量



正常と異常で分布が異なり，ある程度分離可能。  
特に漏洩4については完全に分離可能

## 4. 使用するセンサの最適化



- 宇宙機においては、**搭載するセンサ数が特に制限**される
- 使用するセンサの数はできるだけ減らしたい。**
- センサの組合せは  $2^n$ 通り存在するため、総当たり法は困難  
⇒ **貪欲法を用いてセンサ数を削減**する



## 4. 最適化結果

□線形SVMのROC-AUCスコアに対する貪欲法でセンサ削減

⇒ センサは半数未満でも検知精度に影響なし



必要センサ（計13個）：

TT1F: FTPタービン入口温度, QCO1: 酸化剤流量


TCJF TT2F PDF Feng TEXV TT20 PT2F TJM1F TDO PC QCF



## 4. 最適化センサ使った漏洩箇所診断

- 漏洩が検知できたとしても、漏洩位置の確定コストは高い  
⇒ データから漏洩位置を絞り込みたい
- 4つの漏洩位置で $\Delta x$ の分布が異なり、診断が可能.
- ただし、それぞれの $x_A$ に対応する $x_N$ は現状入手困難.

$\Delta x = x_A - x_N$ の散布図 (QCO1, TT1F)



### 【問題及び解決手段】

- 正常・異常データの分布を得るためにSLSのパラメータにバラつきを発生させ、モンテカルロシミュレーションを実施した。

### 【結果】

- 漏洩と正常データは線形手法(Fisherの線形判別分析や線形SVM)で一定程度区別可能。
- 漏洩検知のみに着目すればセンサ数を半数以下に削減可能。
- 漏洩の発生位置ごとにデータの傾向は異なり、対応する正常値が入手できれば判別可能。

1. 再使用ロケットエンジンPHMと研究目的
2. モデルベース/データ駆動型シミュレーションを利用した学習データの生成
3. 二変量解析に基づくデータ駆動型異常検知手法
4. モデルベース/データ駆動を利用したセンサ最適化手法の開発
5. 今後の予定

## 5. 液体ロケットエンジンにおけるPHMの課題と解決策

1. データが少ない. 特に, 異常データ.

⇒ モデルベース/データ駆動型シミュレーションを利用した学習データの生成.

2. センサ故障/システム故障の識別.

3. 定常だけではなく, 起動/停止過渡状態, 制御入力により状態が変化.


4. エンジン個体差, 作動点ドリフト.

⇒ 二変量解析に基づくデータ駆動型異常検知手法の開発

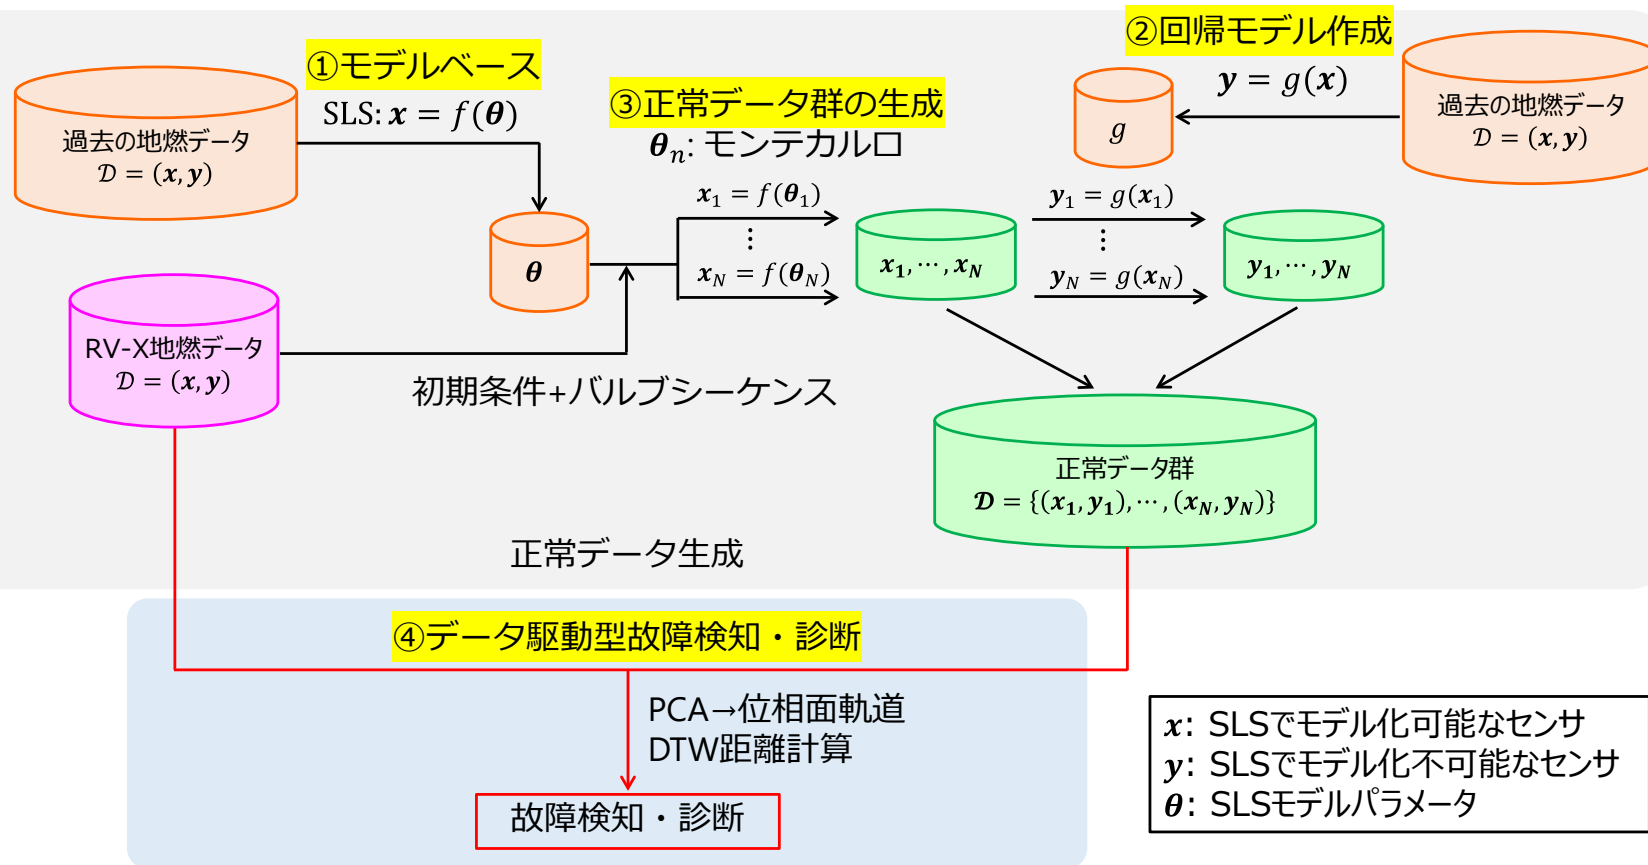
5. 故障予知・診断に対して現状のセンサ配置・点数の最適化

⇒ モデルベース/データ駆動を利用した最適化手法の開発

RSRエンジン地燃データを利用して実証.



# 5. 今後の予定



RV-X地燃@能代

ここで開発してきたPHM手法は、現在、JAXA能代ロケット実験場で進められているRV-X地燃・フライト試験にて実証予定である。