

LOF法を用いた イオン源故障予知モデルの作成と評価

住友重機械工業株式会社

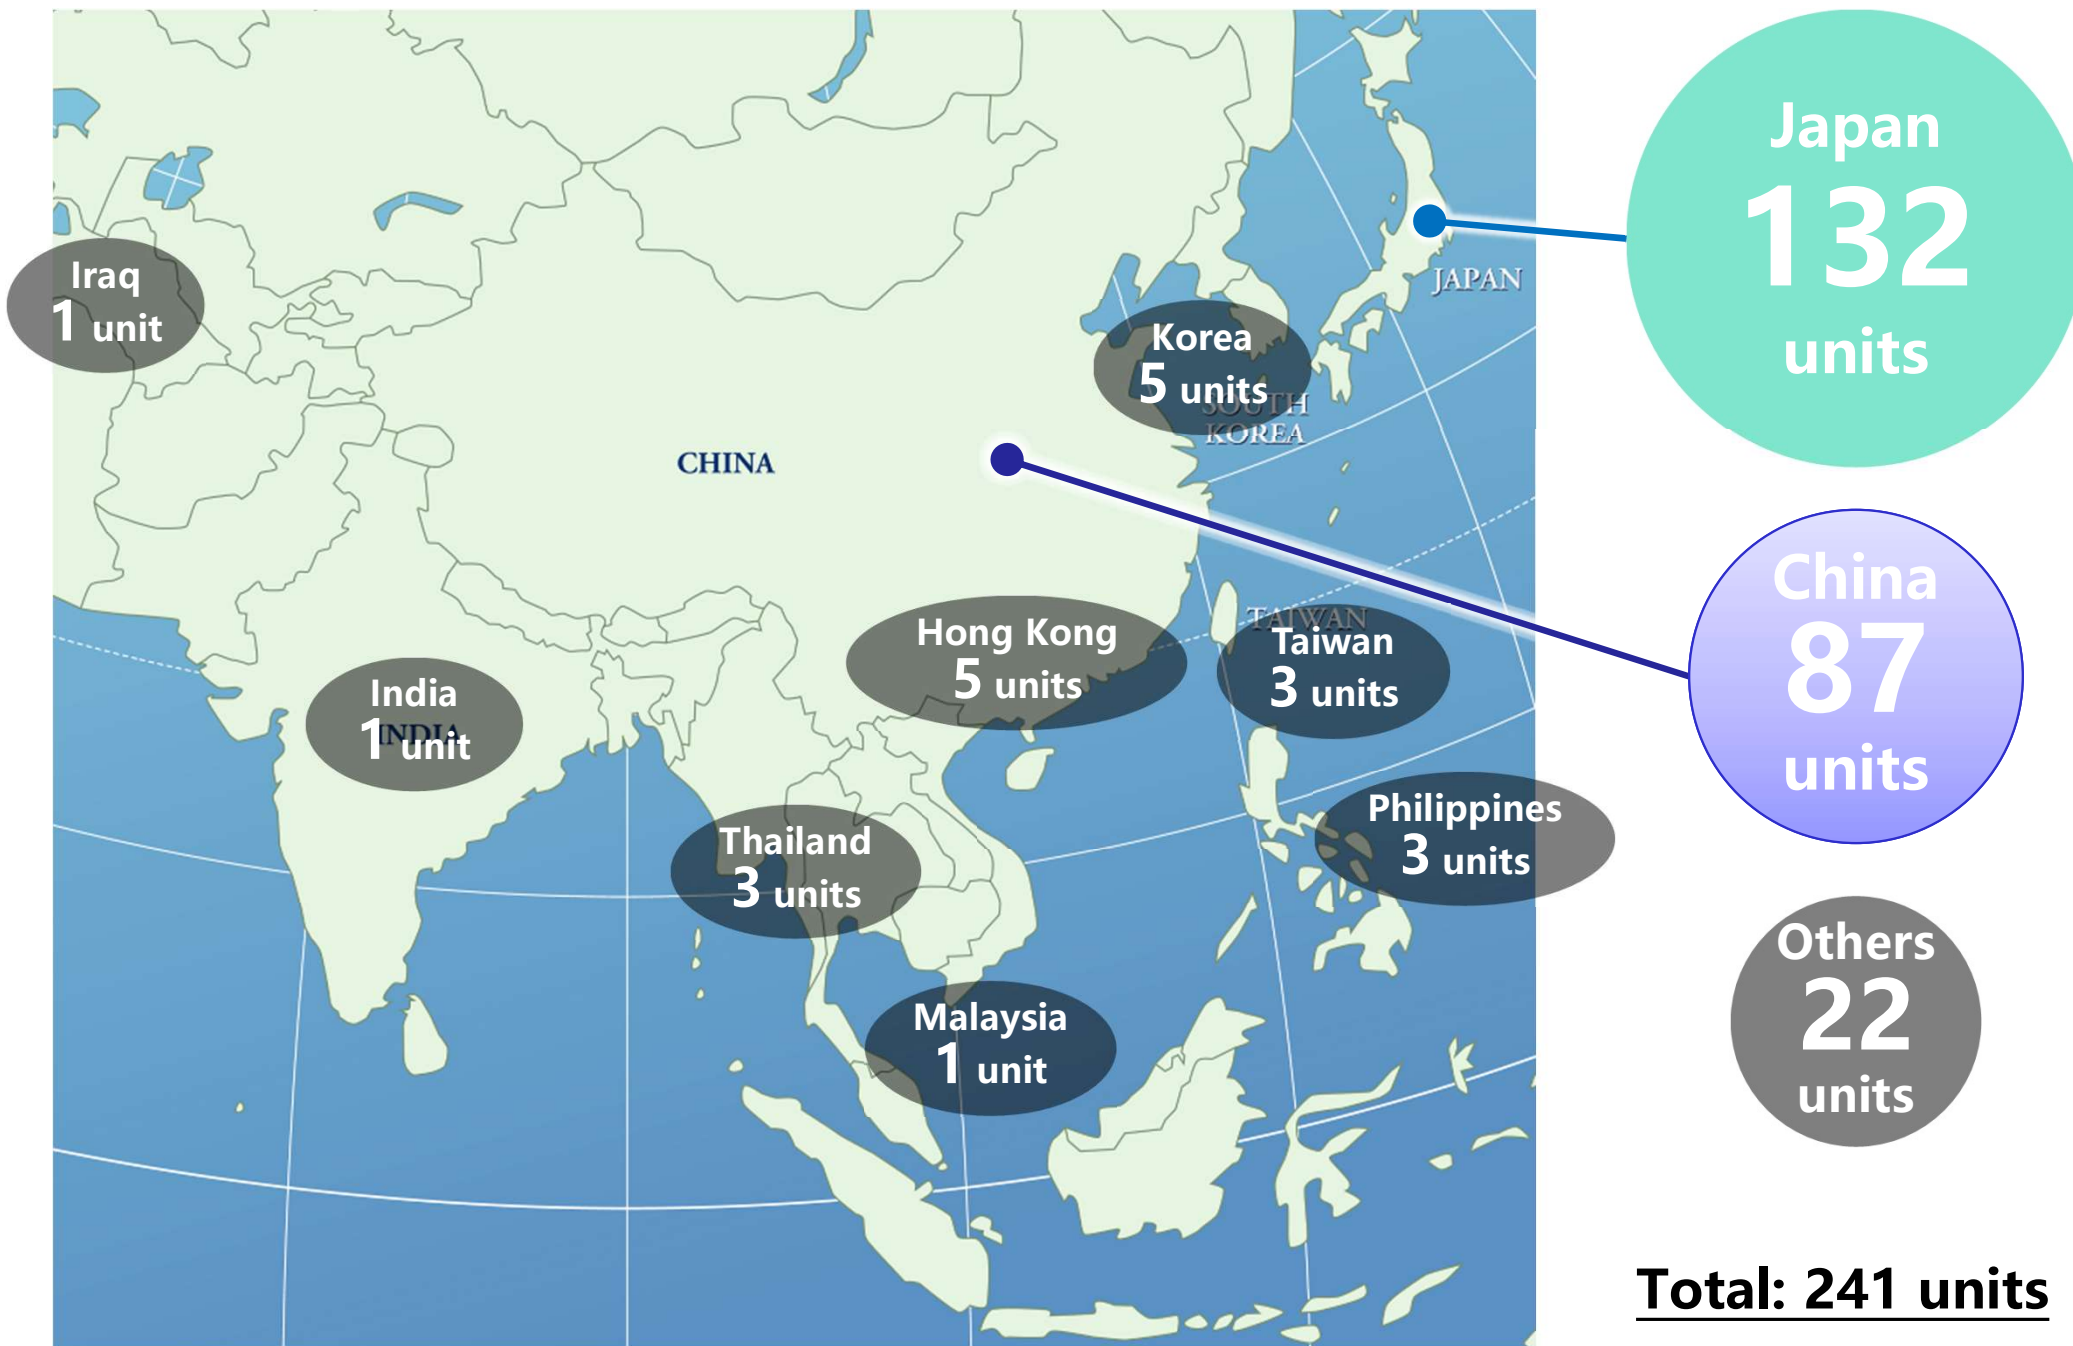
産業機器事業部 医療・先端機器統括部

設計部 電気制御G

丸山真輝

2023年11月28日

背景と目的



HM-20



約2m

- P: 20MeV / D: 10MeV
- Max. 8 targets (2 ports)
- Self-shielding (Option)


HM-12



約1.1m


- P: 12MeV / D: 6MeV
- Max. 8 targets (2 ports)
- Self-shielding (Option)

HM-12SPC



- P: 12MeV
- Max. 4 targets (1 port)
- Self-shielding

製造可能核種： ^{11}C , ^{13}N , ^{15}O , ^{18}F , ^{64}Cu , etc...



心疾患,悪性腫瘍(癌),てんかんの診断、治療,に利用

•当社は病院や研究機関向けにPET診断薬剤製造用小型サイクロトロンを納入し、アフターサービス事業(定期メンテナンス、運転員派遣)をおこなっている。

高リスクトラブル：「カソードショート」(PETサイクロトロン)

事象：イオン源のアノード-カソード間がショート(短絡)する現象。

原因：アーク放電のスパッタ粉堆積、部品の破損、etc...


頻度：年間10~20件発生

影響：診療中止

対策：半年ごとの定期点検時に清掃or交換



PIGイオン源外観



PIGイオン源内部構造図

[石川順三,イオン源工学,アイオニクス株式会社]



堆積物



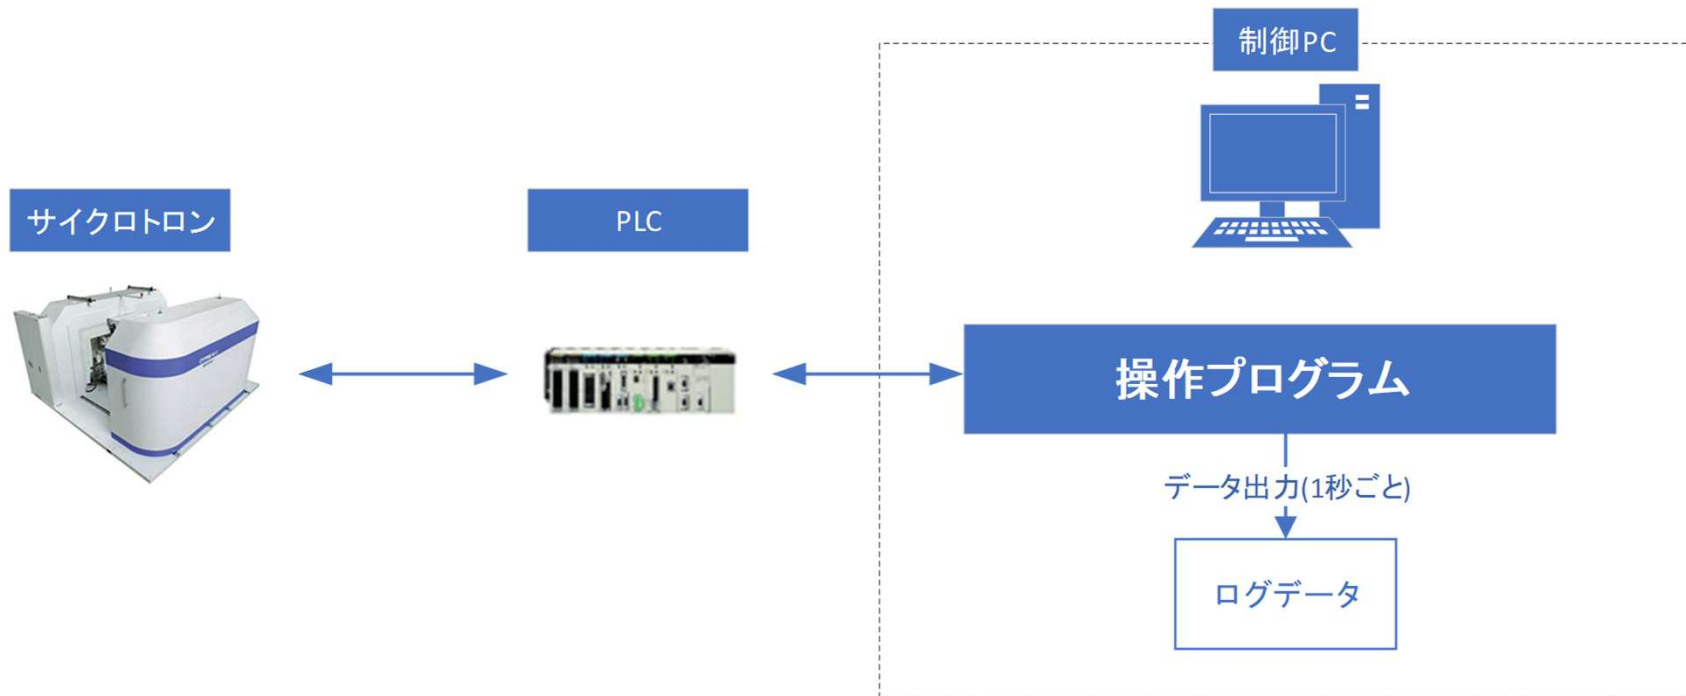
金属片

•装置の状態を監視し、故障を未然に防止したい。→ 機械学習の利用を検討した。

目的(要求仕様)

1. 故障発生前にユーザーへ通知するシステムを構築する。
2. 前日~故障発生1か月前までに通知する。
 - 現地訪問→メンテナンスにより未然防止が可能。
 - 故障ギリギリまで使用したい。(とりあえず1か月)
3. 予測精度が高いモデルを作成する。
 - 故障の見逃し件数を減らす。
 - 適合率(故障が発生した通知/全通知)を高くする。(イオン源メンテナンスが可能な人員が施設に常駐していない。技術者が数日間出張しなくてはならない。)

LOF法を用いた 故障予知モデルの作成と評価



出力データ


- ターゲットビーム電流
- DEE電圧
- イオン源電圧/電流
- 真空度
- ガス流量
- スリット電流
- 引出フォイル検出電流
- etc...

施設Aメンテナンス後のトレンドデータ

立ち上げ ←→ 照射 ←→


ビーム電流[μA]

“照射開始”ボタン押下




- 2023-02-08 08:54:51
- 2023-02-08 10:02:51
- 2023-02-09 08:59:04
- 2023-02-09 09:29:11
- 2023-02-09 10:18:38
- 2023-02-13 08:51:06

イオン源電圧[V]



- 2023-02-08 08:54:51
- 2023-02-08 10:02:51
- 2023-02-09 08:59:04
- 2023-02-09 09:29:11
- 2023-02-09 10:18:38
- 2023-02-13 08:51:06


イオン源電流[A]



- 2023-02-08 08:54:51
- 2023-02-08 10:02:51
- 2023-02-09 08:59:04
- 2023-02-09 09:29:11
- 2023-02-09 10:18:38
- 2023-02-13 08:51:06

真空度[$10\text{e-}6\text{Pa}$]


※有効数字2桁で出力される



- 2023-02-08 08:54:51
- 2023-02-08 10:02:51
- 2023-02-09 08:59:04
- 2023-02-09 09:29:11
- 2023-02-09 10:18:38
- 2023-02-13 08:51:06

DEE電圧[kV]

※右図はプロトン加速時のみ。
デューテロンは異なる電圧で運転。

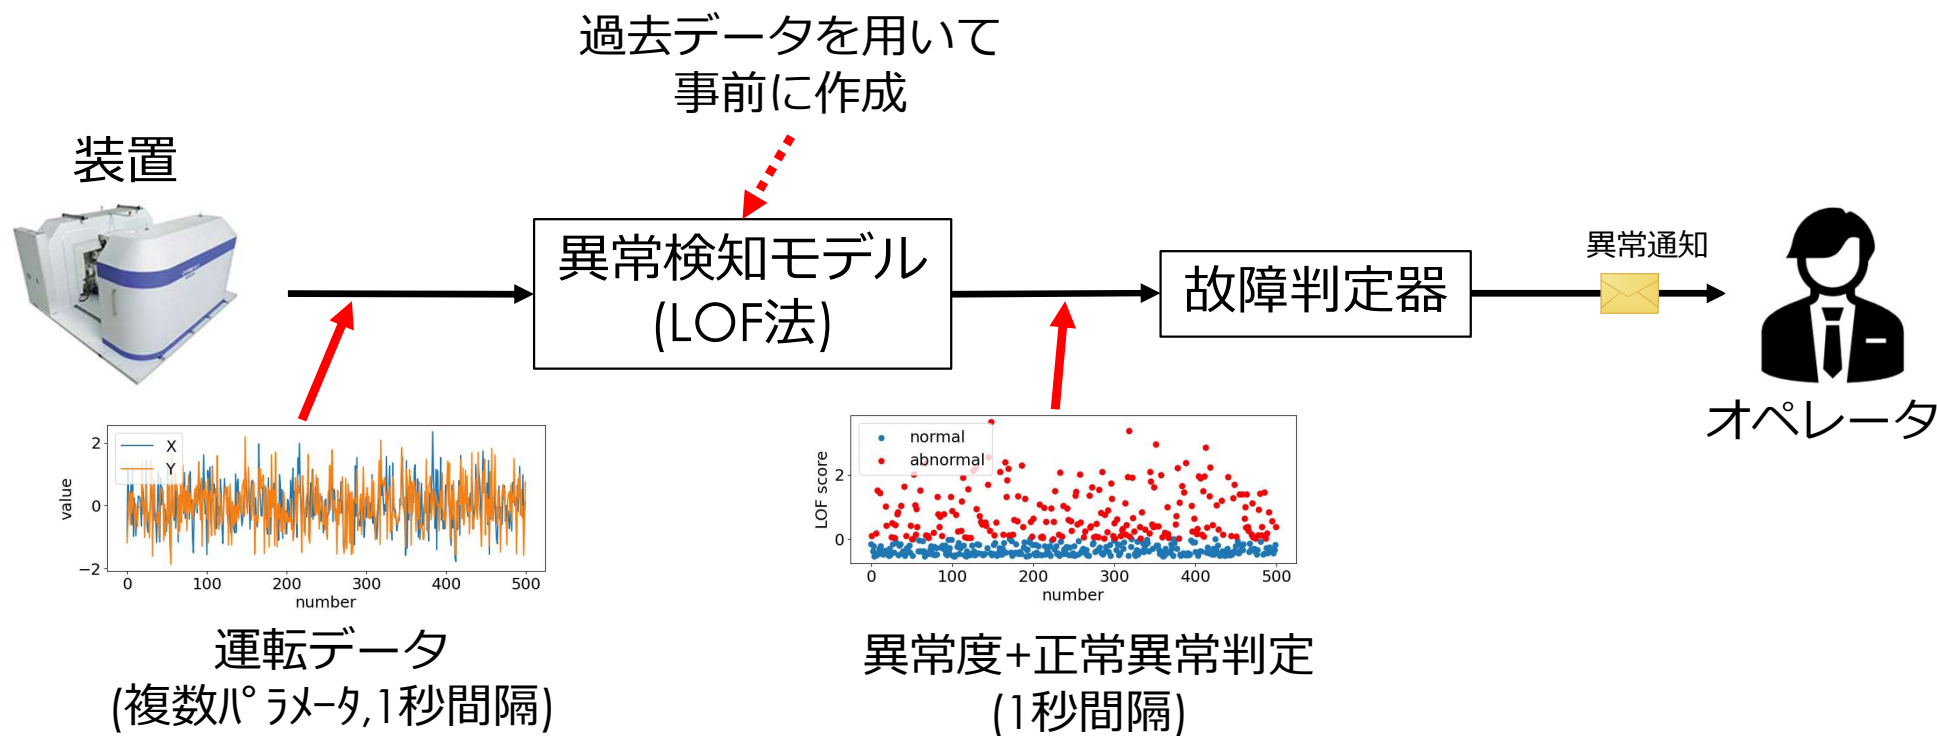


- 2023-02-08 08:54:51
- 2023-02-08 10:02:51
- 2023-02-09 08:59:04
- 2023-02-09 09:29:11
- 2023-02-09 10:18:38
- 2023-02-13 08:51:06

機械学習を用いた異常検知手法の比較

アプローチ	モデル例	説明	メリットとデメリット
データの距離と密度	LOF法 (局所外れ値因子法)	データの距離と密度で異常度を算出する。	○：アイデアがシンプル。複雑なデータで動作しやすい。 ×：計算量が多い。入力パラメータ10個程度まで。
分類	Support Vector Machine	データの正常・異常を分ける境界を求める。	○：少数のデータで学習可能。 ×：複雑なデータは動作しない場合がある。
再構築	Auto Encoder, RBM	データの次元削減→復元を行い、復元率が低いデータを異常と判定する。	○：次元が多いデータに対応可能。 ×：説明性が低い。

LOF法を用いた故障予知フロー



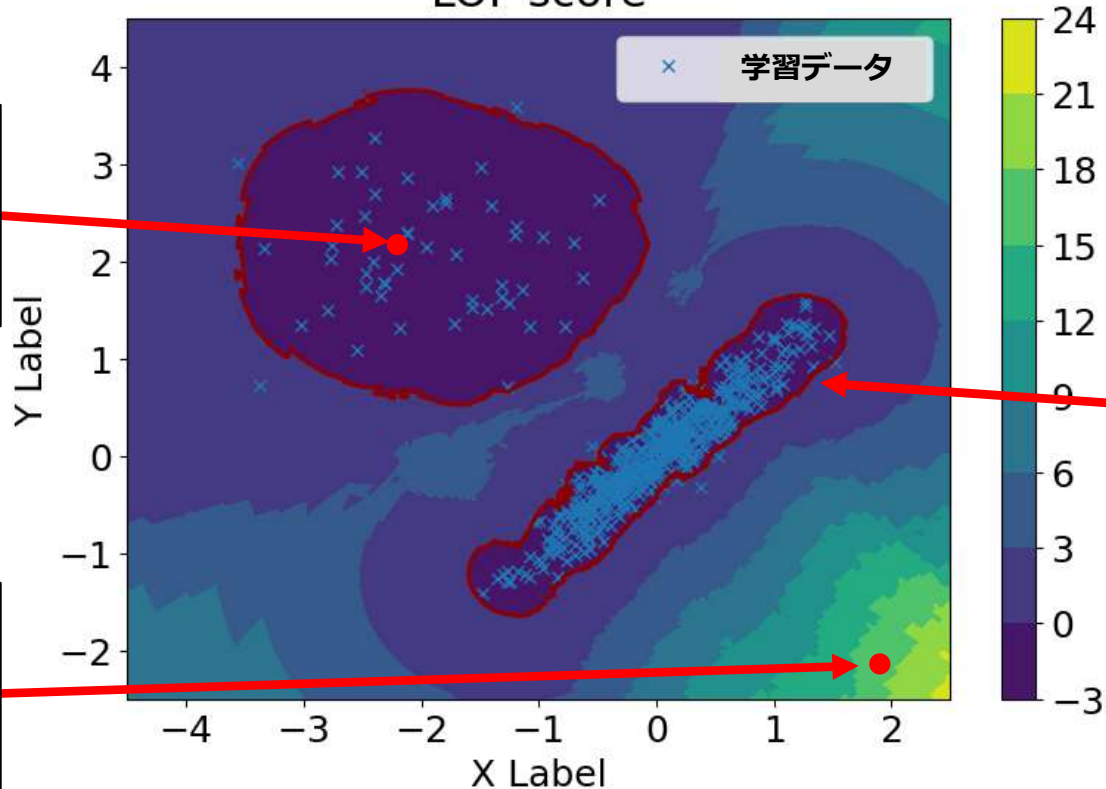
LOF法(局所外れ値因子法)

- ① 入力データの近傍にある"k"個の学習データの密度、およびその近傍点それぞれの周囲のデータの密度を比較して入力データの異常度を出力する。

$$LOF \text{ 異常度 } \alpha = \frac{1}{k} \cdot \sum_{i=1}^k \frac{lrd_i}{lrd_p} \quad \text{局所密度 } lrd = \left(\sum_{i=1}^k \frac{d_i}{k} \right)^{-1}$$

- ② 学習データに交じる異常データの割合(contamination)を設定することで正常と異常の境界線を引き、入力データの正常/異常判定を出力する。

LOF score



①
周囲に学習データがある
→異常度：低

①
周囲に学習データが無い
→異常度：高

②
境界線の内側：正常
境界線の外側：異常

注)説明用にダミーデータを使用
(当社装置のデータではありません)

モデル諸元と作成手順

1. データ抽出

- 照射開始ログ
- トレンドデータ
 - 照射開始300秒間(1秒間隔)
 - **パラメータ:**
 - イオン源電圧
 - イオン源電流
 - 真空度
 - DEE電圧

2. 学習データ

- メンテナンス3日後から17日後(2週間)

3. 学習

- 前処理
 - 重複除去
 - 標準化
- **学習(LOF法,k=10,contamination=0.001)**

4. テスト

- テストデータ抽出
- 標準化(学習データの σ, μ を使用)
- 異常度、異常判定結果を出力(1秒間隔)

```

1 #操作ログデータから照射開始ログを抽出。(T1秒後~T2秒後)
df_irr_log = PET_CYC_IRR_LOG(machine_type,facility_name,strday,endday)

#照射ごとに、照射開始ログのT1秒後~T2秒後を抽出して辞書型に格納。(key=照射開始ログ時刻)
dic_df_irr = PET_CYC_data(machine_type,facility_name,df_irr_log,list_para,T1,T2)

2 #メンテナンス実施日のd1日後からd2日間のデータを学習データとして抽出。
df_train = ext_df_train(dic_df_irr,day_maintenance,d1,d2)
✓ 1.5s

3 def preprocess_train(df_train,list_para):
    #欠損しているデータを除去
    df_train.dropna(how='any',axis=0,inplace=True)
    ##結果が発散しないようにするために、まったく同じデータは重複除去する。
    df_train.drop_duplicates(subset=list_para,inplace=True,keep="last")
    #入力データと規格化
    x = df_train[list_para].values
    autoscaled_x = (x - x.mean(axis=0)) / x.std(axis=0)

    return x,autoscaled_x
✓ 0.0s

#学習データの前処理
x,autoscaled_x = preprocess_train(df_train,list_para)

### LOF学習
from sklearn.neighbors import LocalOutlierFactor
k = 10
contamination = 1e-3
model_lof = LocalOutlierFactor(n_neighbors=k, novelty=True, contamination=contamination)
model_lof.fit(autoscaled_x)
✓ 0.0s


LocalOutlierFactor
LocalOutlierFactor(contamination=0.001, n_neighbors=10, novelty=True)

4 #テストデータの抽出
df_test = ext_df_test(dic_df_irr,day_maintenance,d1,d2)


##テストデータの前処理
x_test = df_test[list_para].values
#学習データ空間で距離(異常度)を算出するため、学習データの平均、分散を使用してテストデータを標準化
autoscaled_x_test = (x_test - x.mean(axis=0)) / x.std(axis=0) #規格化

#異常値
lof_test = model_lof.decision_function(autoscaled_x_test)
#判定結果
lof_predict = model_lof.predict(autoscaled_x_test)
✓ 0.0s
    
```



異常度,異常判定結果




異常データ数積算




異常データ数/データ数
(1日毎)




異常データ数/データ数
(1日毎,過去最大値)




異常度,異常判定結果




異常データ数積算



異常データ数/データ数
(1日毎)




異常データ数/データ数
(1日毎,過去最大値)



通知条件：異常データ数/データ数(1日毎)の過去最大値が更新されたとき。

異常データ数/データ数
(1日毎,過去最大値,施設A)



施設名	型式	故障発生日	異常データの割合の最大値更新で通知			
			30日以内に 故障発生した 通知の数(①)	全通知数 (②)	故障予知 結果	適合率[%] ①/②
施設A	HM-20	2023/1/16	1	4	○	25
施設B	HM-20	2022/8/9	1	3	○	33
施設C	HM-18	2023/8/31	1	2	○	50
施設D	HM-12	2022/6/20	0	2	×	0
施設E	HM-12	2022/5/23	2	2	○	100
施設E	HM-12	2022/7/23	0	0	×	-
施設F	HM-7	2022/9/22	3	4	○	75

- 7回の故障のうち5回で故障発生前30日間に通知を行うことができた。
- 適合率：約47%。
- 今後の課題：
 - ①見逃し削減、適合率向上(パラメータ変更、他機械学習手法との比較)
 - ②故障予知システム構築

故障予知システム構築

住友重機械のIoTプラットフォーム

×

異常検知ソリューションImpulse(ブレインズテクノロジー(株))

→GUIベースで機械学習を活用して故障予知モデル作成、運用および要因分析が可能。

I : Impulseで故障予知モデル作成→SHIのクラウドからAPI実行

※当社で検討中の
Impulse利用方法



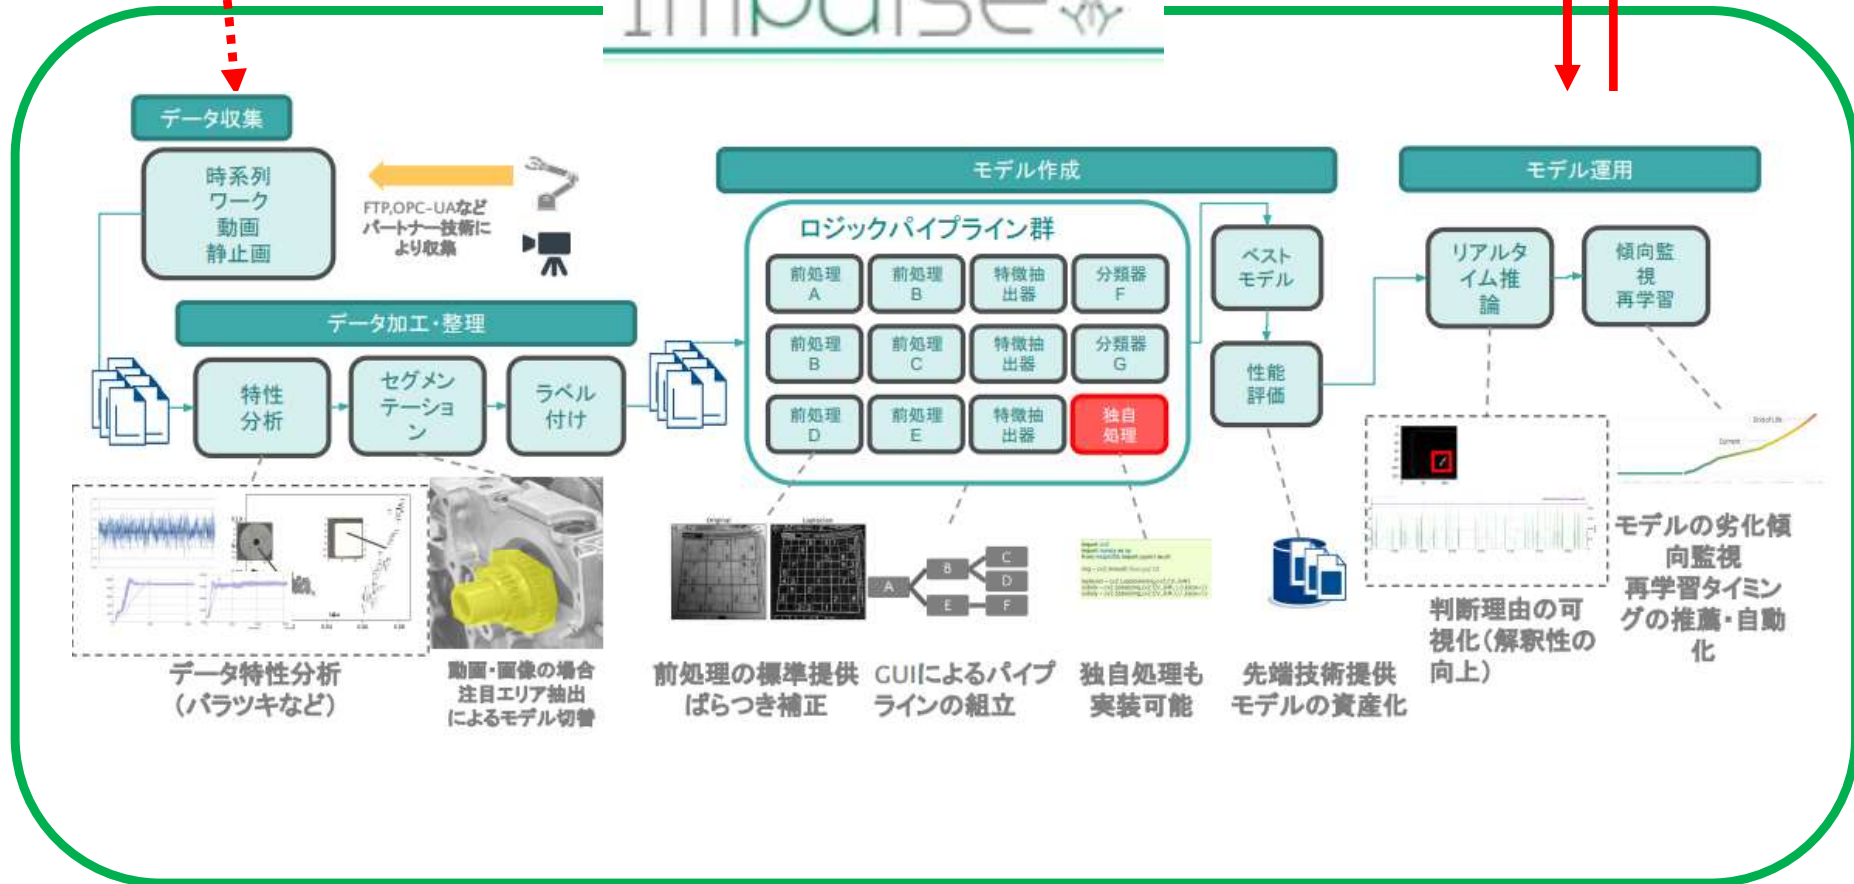
遠隔データ収集



住友重機械IoTプラットフォーム

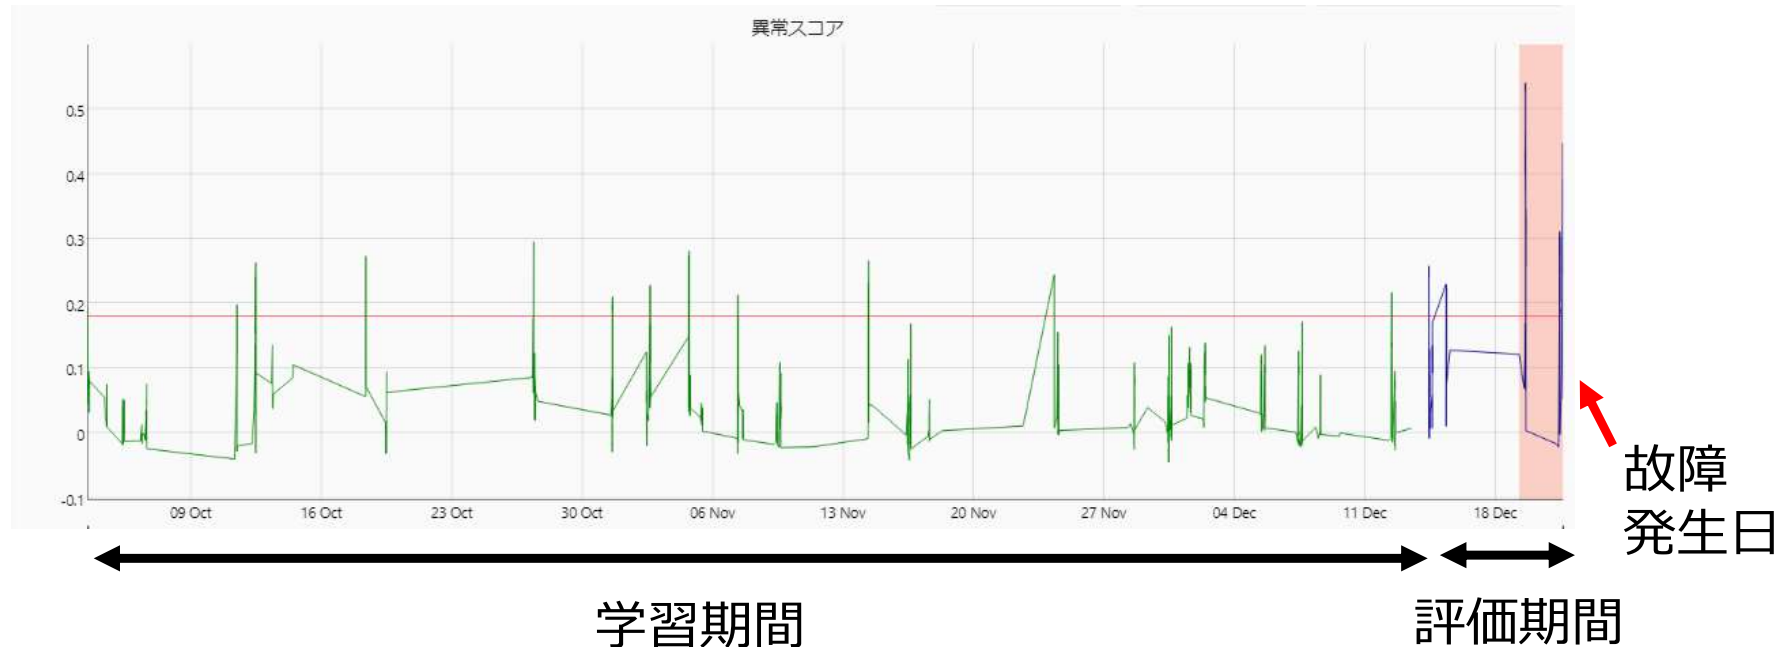
過去データ

データ ↓ スコア,判定結果 ↑




Ⅱ：トラブル時のデータ分析→故障要因の特定

①故障発生前に異常度が上昇するモデルを選択+閾値を設定(正常/異常ラベル付け)



②①のラベルを元に要因分析。

マトリクス概要(パレート分析)



良品基準

Name	Condition
[Rule 0]	BT#DIAG#B-SL1#1R_LLA < 1.4642 and CYC#TMP#C-TMP#SEC1_TMP_A < 33.218 and CYC#VAC#C-VPU#CRP2_TMP_A < 10.368

不良品基準

Name	Condition
[Rule 1]	BT#DIAG#B-SL1#1R_LLA >= 1.3311 and CYC#DIAG#C-FM1#LA >= -0.97188 and CYC#TMP#C-TMP#SEC1_TMP_A >= 31.295 and CYC#VAC#C-VPU#CRP2_TMP_A >= 10.164

まとめと今後の予定

まとめ

当社PETサイクロトロン「カソードショート」について、機械学習手法を用いた故障予知システムの導入に向けた検討を行った。

- ✓ LOF法を用いた故障予知モデルを作成した。
 - 7回の故障のうち5回で故障を予知することができた。
 - 適合率：約47%
- ✓ 当社IoTプラットフォームとImpulseを利用した故障予知システムの構築を検討した。

今後の課題

- 予知できなかつた故障の再検討
 - 適合率向上
 - システム構築
 - 当社他装置への展開(陽子線治療装置,BNCT,etc...)
- } パラメータ変更
他機械学習手法との比較

以上です。
ご清聴ありがとうございました。

原理：LOF法による異常度算出 (近傍数=2、点A~Dを学習データ、点Pを検証データとした場合)

①点Pとその近傍点の局所密度を算出する

$$\text{局所密度 } lrd = \left(\sum_{i=1}^k \frac{d_i}{k} \right)^{-1}$$

近傍点
それぞれまでの
距離

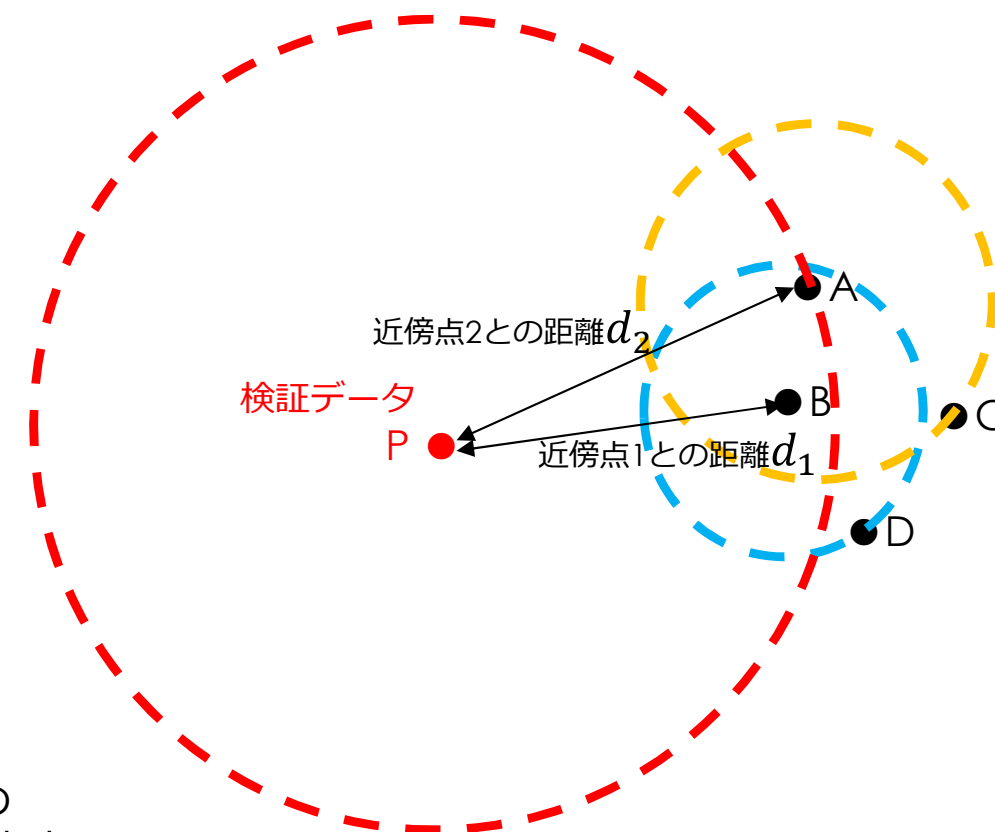
②異常度を算出する

$$\text{異常度 } \alpha = \frac{1}{k} \cdot \sum_{i=1}^k \frac{lrd_i}{lrd_p}$$

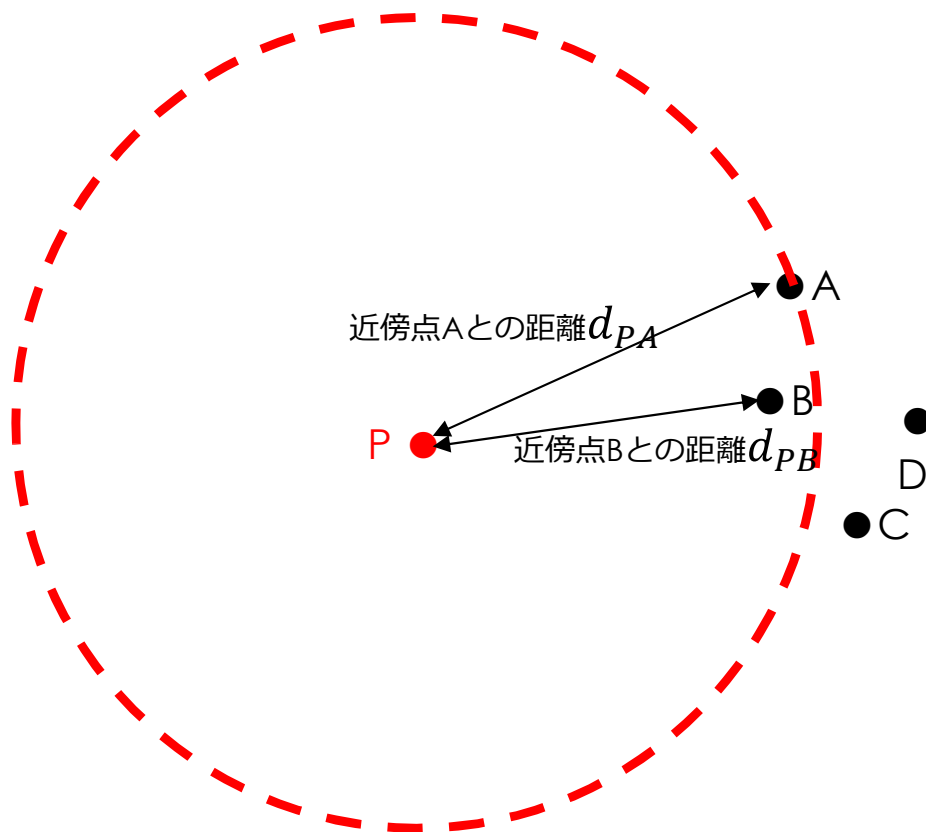
近傍点
それぞれの
局所密度

$$= \frac{1}{k} \cdot \frac{lrd_A + lrd_B}{lrd_p}$$

点Pの
局所密度



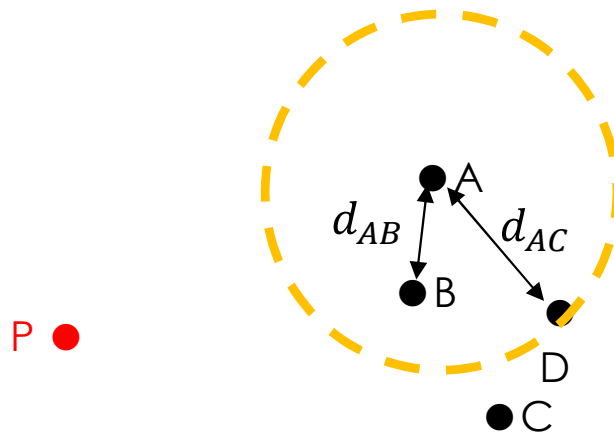
•点Pの局所密度と比較して点A,Bの局所密度が高いほど異常度は高くなる。



K=2のとき、
Pの最近傍点はA,B

$$lrd_P = 1 \div \sum_{i=1}^k \frac{d_i}{k}$$


$$= k / (d_{PA} + d_{PB})$$



K=2のとき、
Aの最近傍点はB,D

$$lrd_A = 1 \div \sum_{i=1}^k \frac{d_i}{k}$$

$$= k / (d_{AB} + d_{AC})$$




K=2のとき、


Bの最近傍点はA,C

$$\begin{aligned} lrd_B &= 1 \div \sum_{i=1}^k \frac{d_i}{k} \\ &= k / (d_{BA} + d_{BC}) \end{aligned}$$


異常度,異常判定結果




異常データ数積算




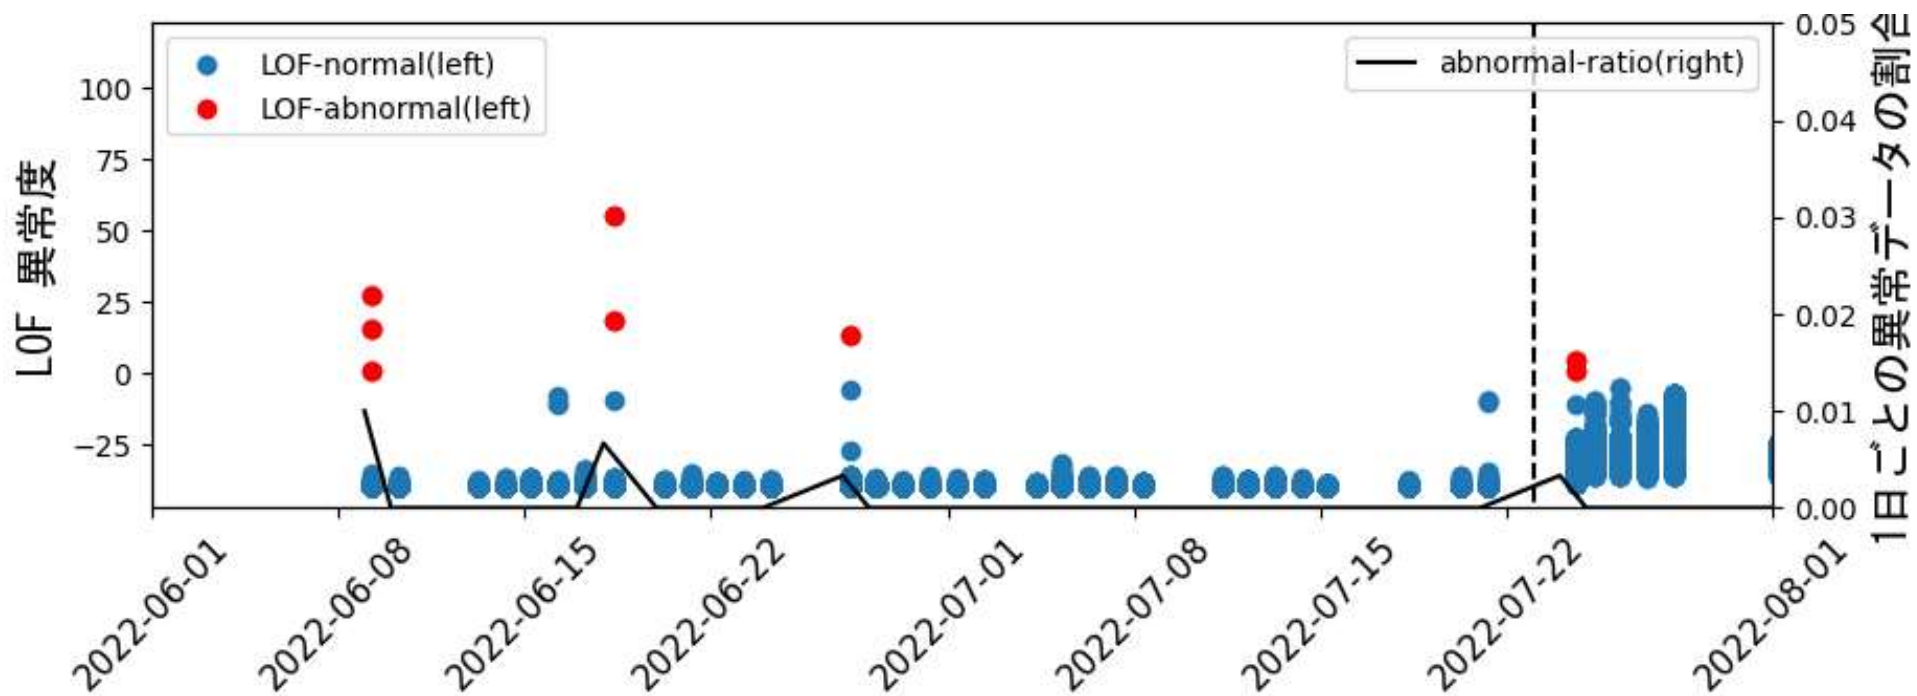
異常データ数/データ数
(1日毎)

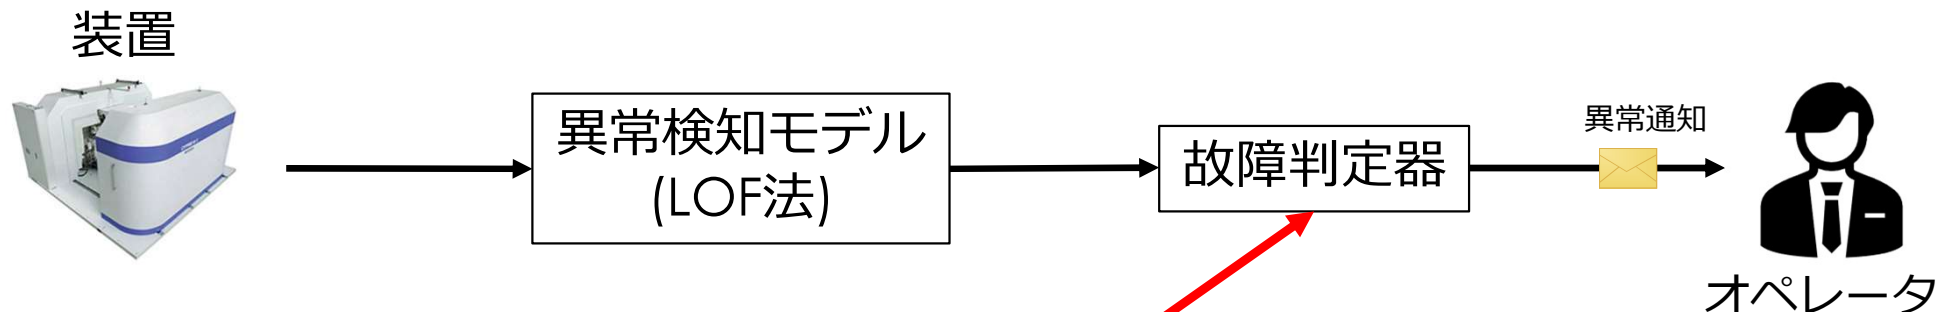


異常データ数/データ数
(1日毎,過去最大値)










故障判定条件(通知を送る条件)

1. 対象
 1. 1秒ごとのデータ
 2. 特定の期間ごと(1分/1時間/1日、運転1セット)の統計値
 3. 積算
2. 方法
 1. 閾値
 2. 変化点



過去データで検証を行い、予知したい故障ごとに判定条件を設定する。