

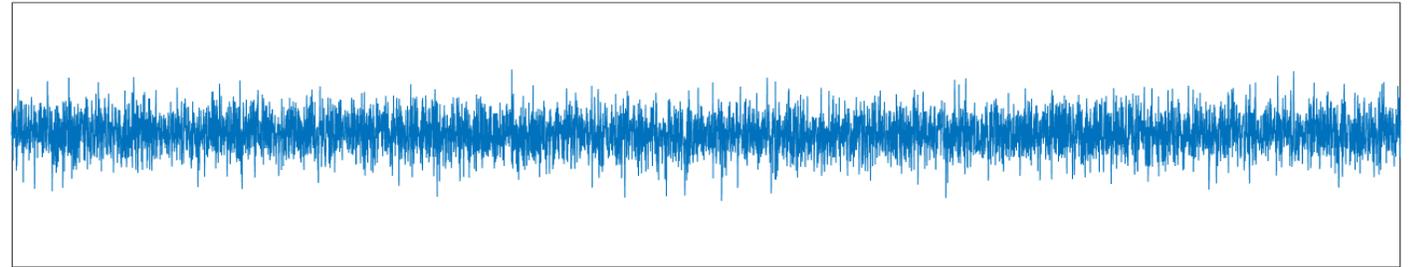
MATLAB EXPO 2018

生産技術向け故障予測・予知保全

アプリケーションエンジニアリング部
井上 道雄



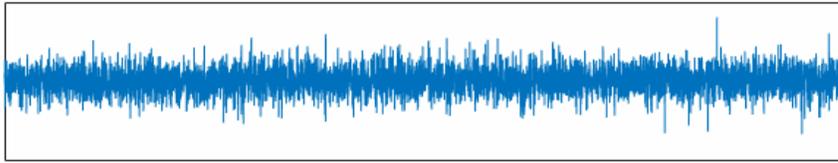
異常検知・故障予測の予知保全への応用



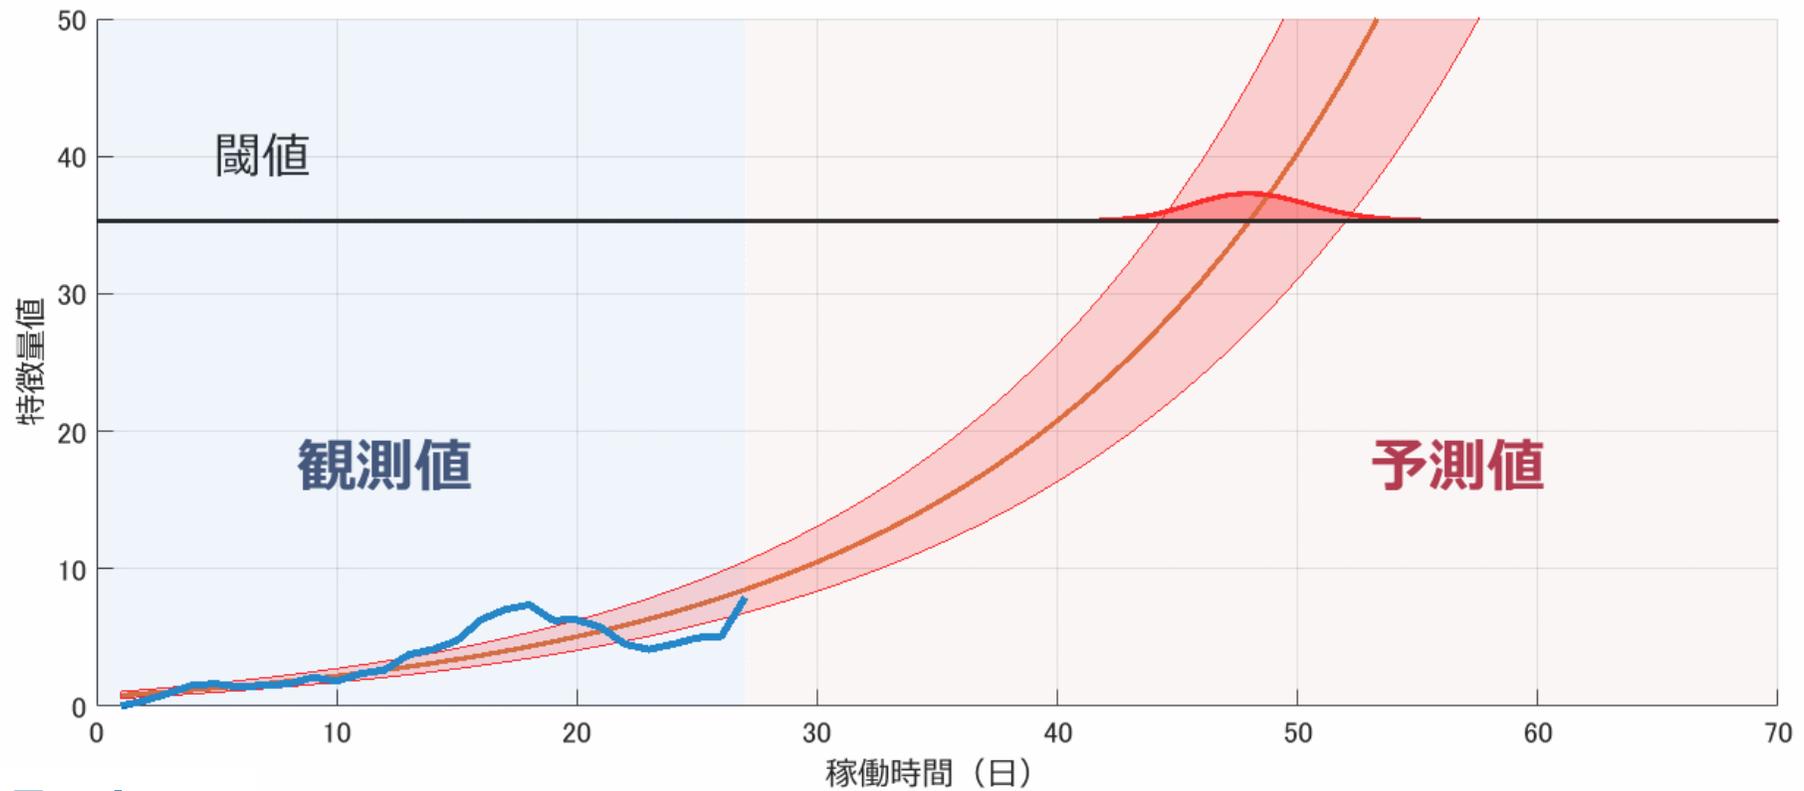
Site Engineer

Needs maintenance.
One of bearings being failed.
It will shut down in 15 hours.

異常検知・故障予測の解析例



故障まで残り 499 時間
(95%信頼区間：406~599 時間)



Site Engineer

予知保全で直面する 4 課題

- ✓ 十分な量のデータがない
- ✓ 十分な量の故障データがない
- ✓ 故障予測の方法が分からない
- ✓ 予知保全アルゴリズムの構築方法が分からない

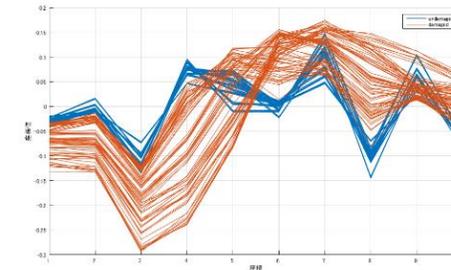


こちらからDL：[予知保全で直面しやすい4つの課題とその対処法](#)

アジェンダ

生産技術向け故障予測・予知保全

- 故障予測システムの開発事例
- 故障予測を可能にする特徴量とは
- Demo：風力タービンの故障予測
- まとめ

The Mondri logo consists of a stylized orange and red shape to the left of the word "mondi" in a lowercase, sans-serif font.The Baker Hughes logo features a blue square with a white stylized 'B' and 'H' inside, followed by the words "BAKER HUGHES" in a bold, uppercase, sans-serif font.

故障警告システムの開発事例

包装・製紙メーカー：Mondi Gronau社（ドイツ）

課題

プラスチックフィルム製造工場で
廃棄と機械ダウンタイムを減らしたい

ソリューション

機械の故障を予測する
監視ソフトウェアの開発・実装

結果

- ✓ 潜在的異常の警告を発信するソフトウェア
- ✓ 年間50,000ユーロを超えるコスト削減

“中断のない安定した運用が可能に”
- Dr. Michael Kohlert (Mondi)



故障警告システムの開発事例

ガス採掘トラック：Baker Hughes社（米国）

- 課題

採掘現場で24時間稼動する装置の稼働率を上げたい

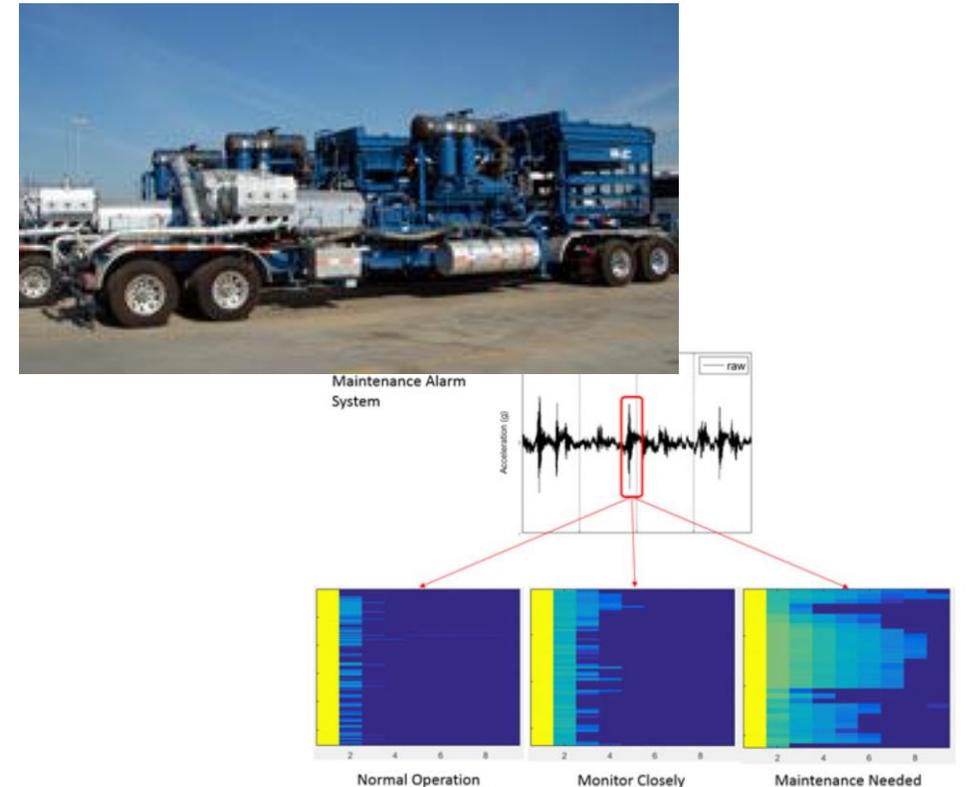
- ソリューション

バルブからの圧力・振動データにスペクトル解析を実施しニューラルネットワークによる故障予測

- 結果

- ✓ \$1000万以上のコスト削減
- ✓ 開発時間90%削減

“最適なメンテナンス時期がリアルタイムで予測可能に”
- Dr. Gulshan Singh (Baker Hughes)



一台あたり: > \$1.5M

修理費: \$100,000

バルブ1個: \$200





アルゴリズム開発フロー：4つのステップ



ビジネスデータ

センサーデータ

データの次元削減

特徴量抽出

モデル作成
機械学習

モデル検証

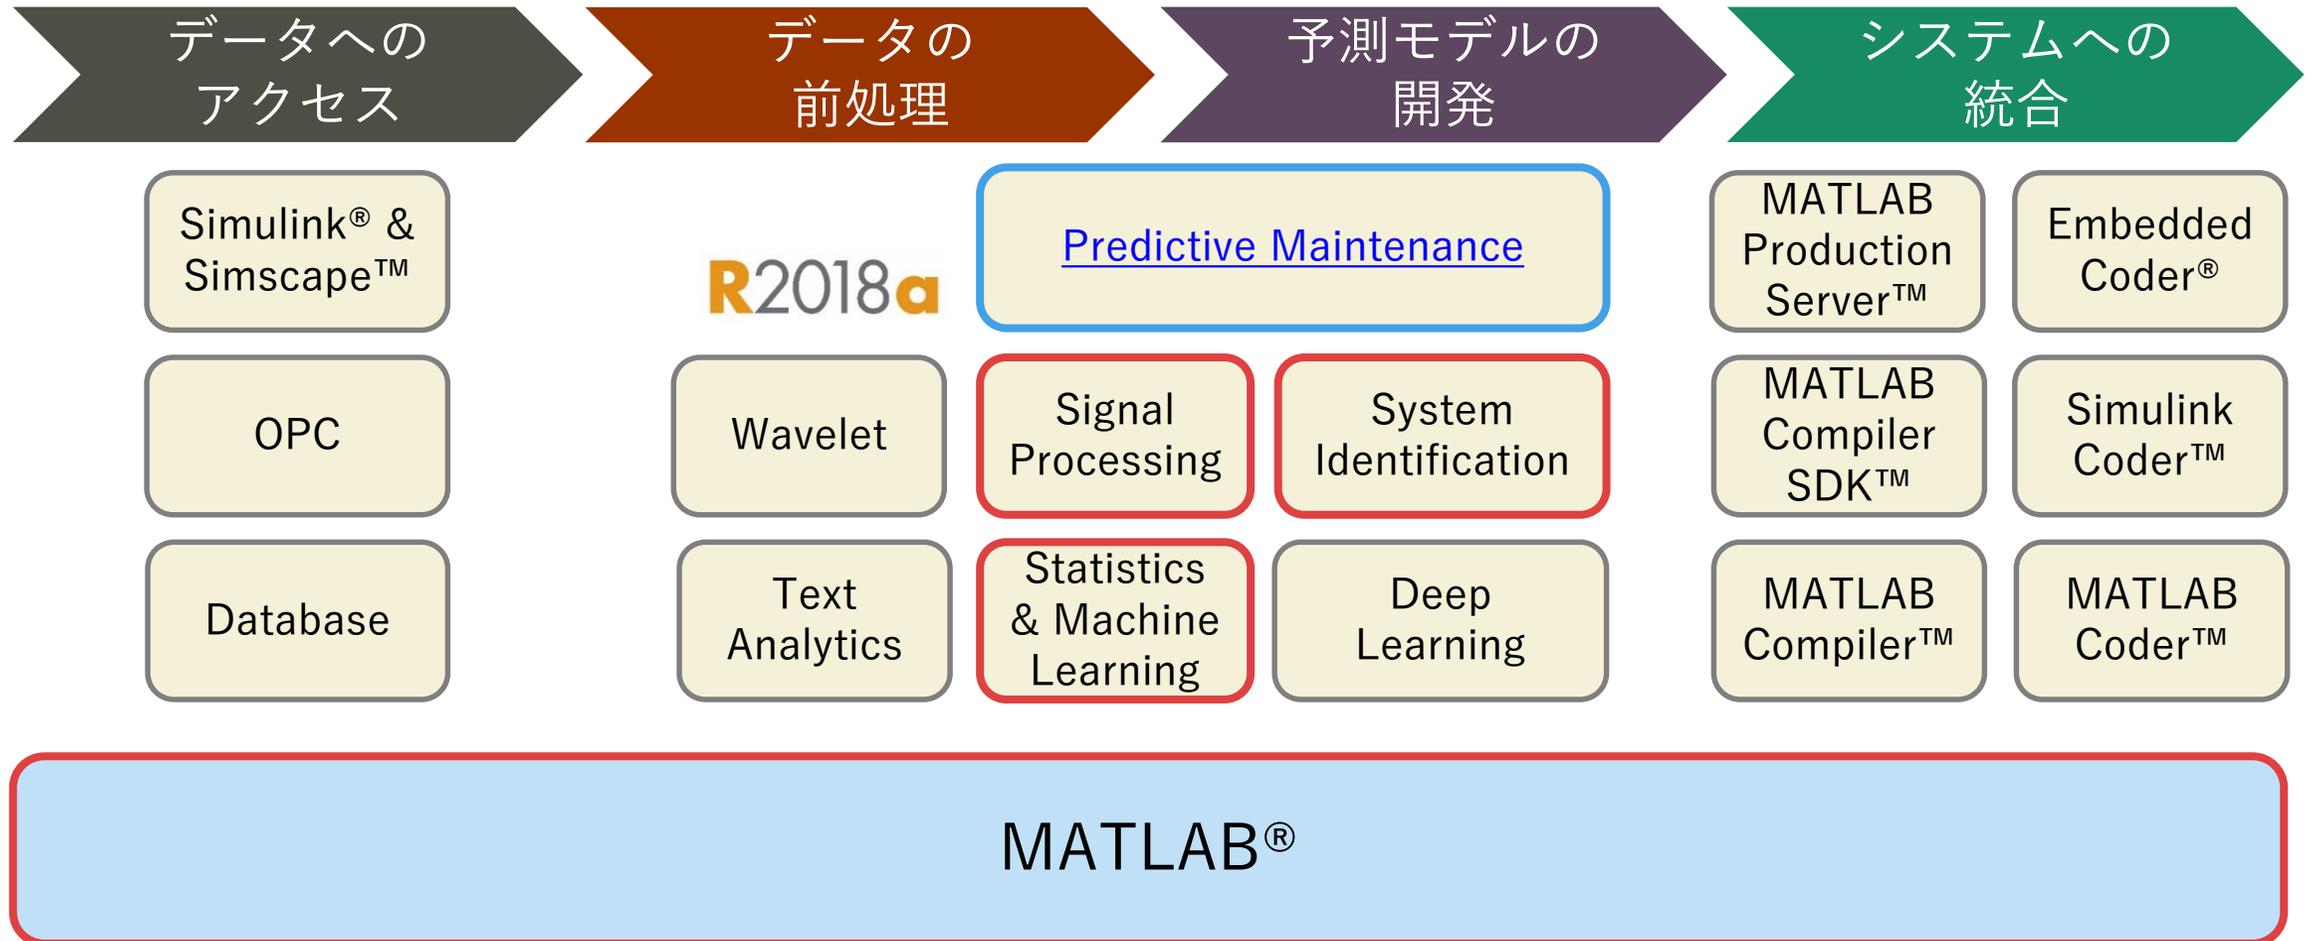
エンタープライズ
システム

MATLAB Excel
.NET C/C++
.exe Java .dll

組み込みデバイス

アルゴリズム開発フロー：4つのステップ

Predictive Maintenance Toolbox™ の導入



Predictive Maintenance Toolbox R2018a

予知保全アルゴリズム開発の効率UP

Get Started with 予知保全

- バッテリーやギアボックスなどの例題
- アルゴリズム開発の流れをまとめたドキュメンテーション ([Link](#))
- 開発の各ステップで使える手法一覧

予知保全向けの機能

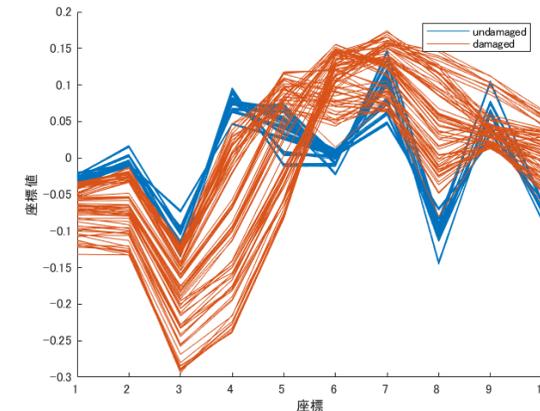
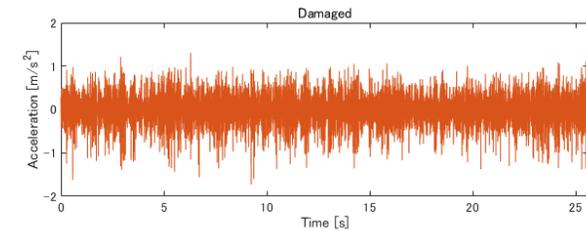
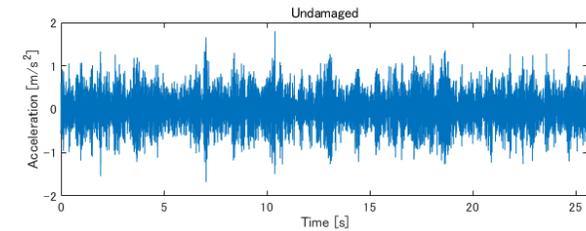
- 予測モデル作成向けのデータ管理機能
- 機器の残り寿命を予測するモデル
- 機器の状況を表す特徴量を抽出する機能
- Simulinkモデルを使った故障データ作成

The screenshot displays the 'Identify Condition Indicators' function page in the Predictive Maintenance Toolbox. The page is titled 'Identify Condition Indicators' with a 'URL' link. Below the title, there is a brief description: 'Explore data to identify features that can indicate system...'. A definition of a condition indicator is provided: 'A condition indicator is a feature of system data whose behavior is any feature that is useful for distinguishing normal from fault or different status apart.' The page also mentions that condition indicators can be derived from signal analysis, dynamic models, and model parameter monitoring. A 'Functions' section is visible, listing several categories: 'Signal-Based Features', 'Model-Based Features and Residuals', and 'Feature Selection'. The 'Preprocess Data' function is also visible in the background.

アジェンダ

生産技術向け故障予測・予知保全

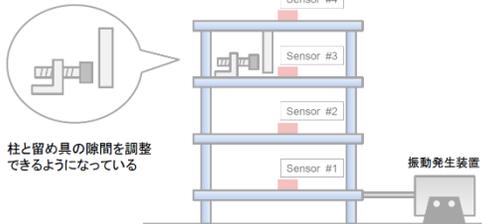
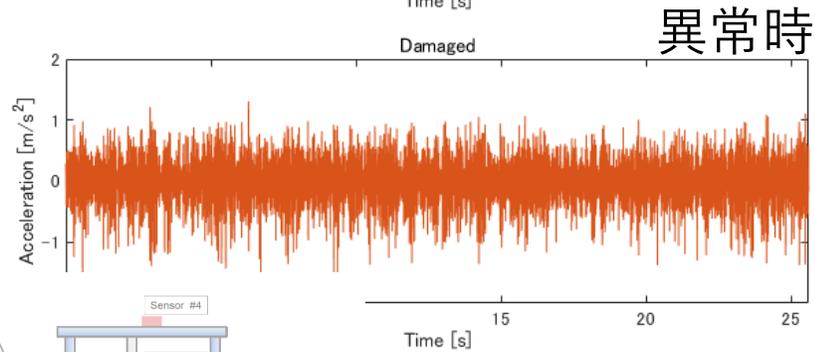
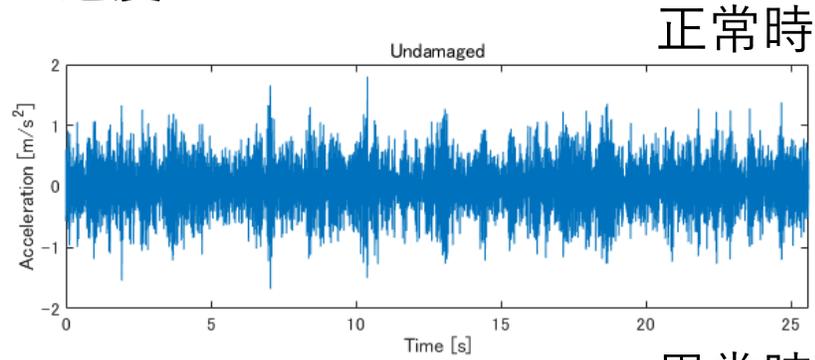
- 故障予測システムの開発事例
- 故障予測を可能にする特徴量とは
- Demo：風力タービンの故障予測
- まとめ



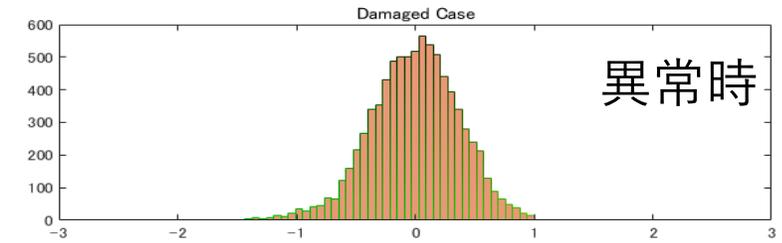
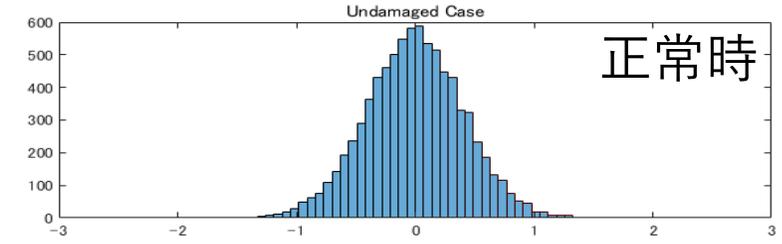
特徴量抽出

異常検知・故障予測の最大の「壁」

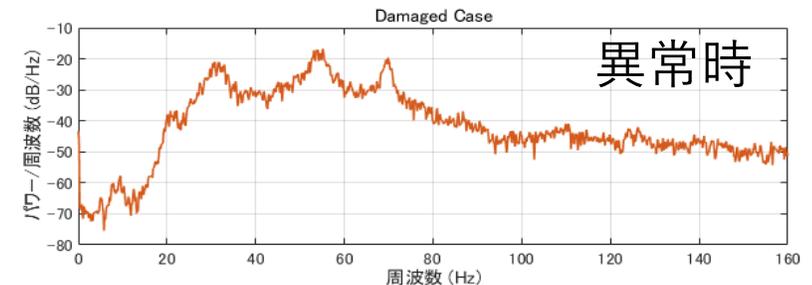
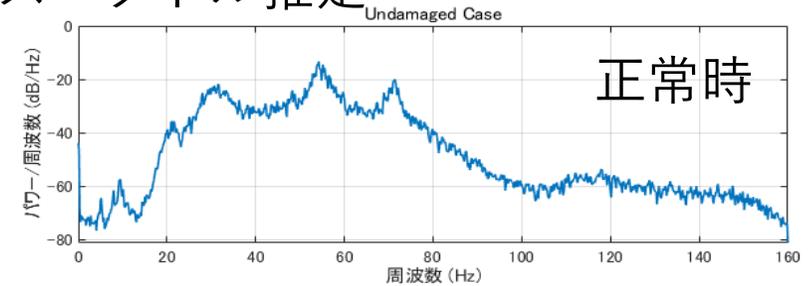
加速度データ



ヒストグラム



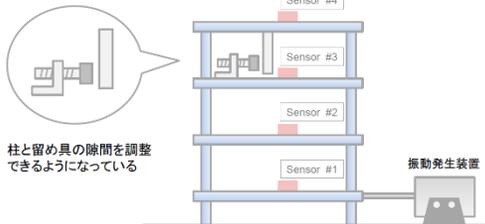
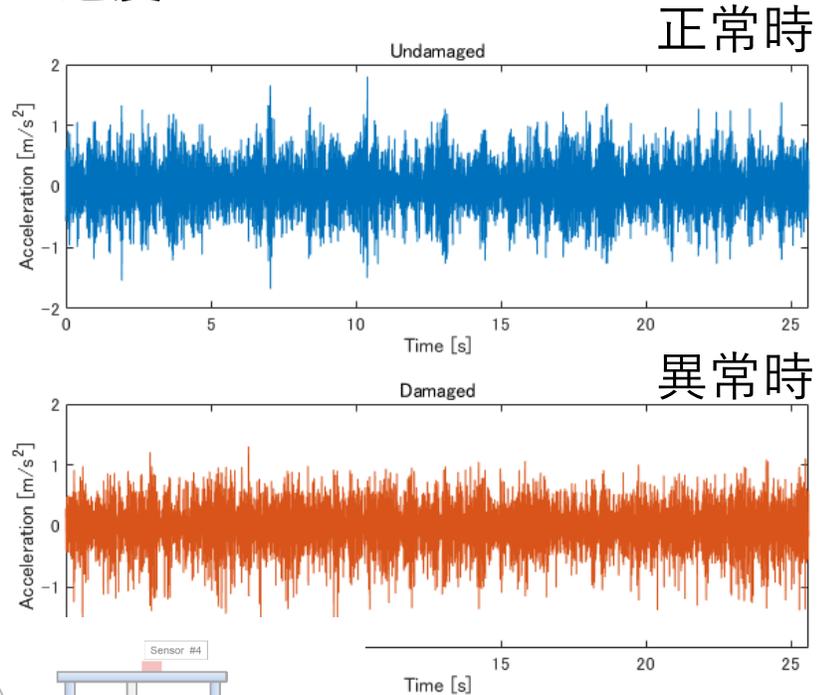
スペクトル推定



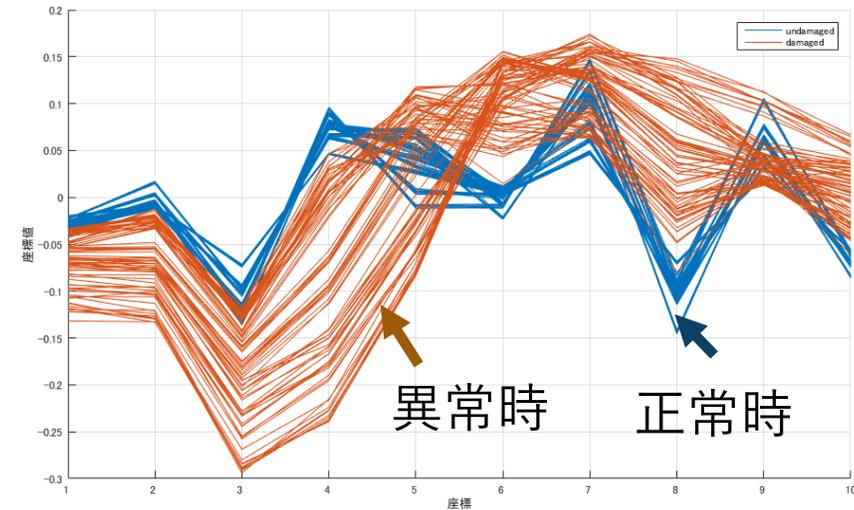
特徴量抽出

センサーデータの前処理が成功の鍵

加速度データ

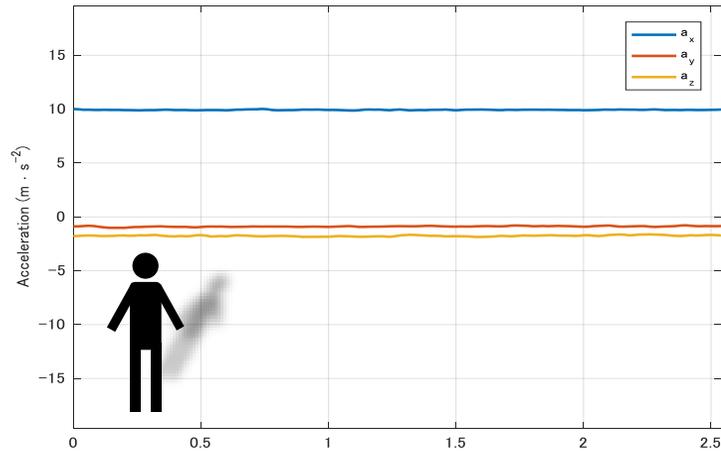


自己回帰モデル係数

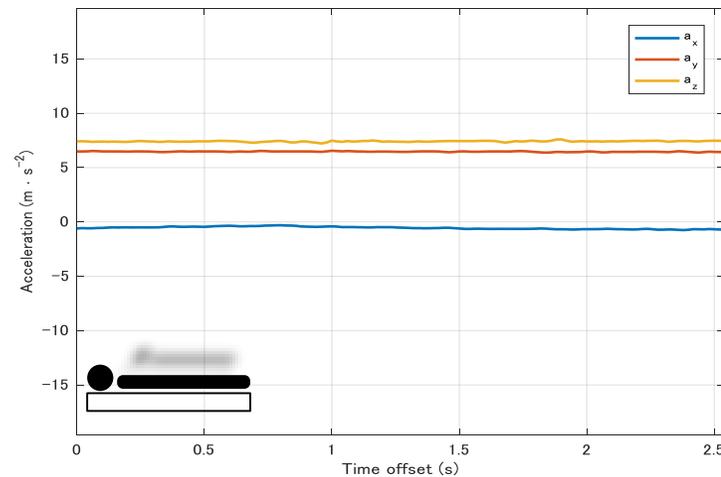


加速度センサー情報による人の活動認識

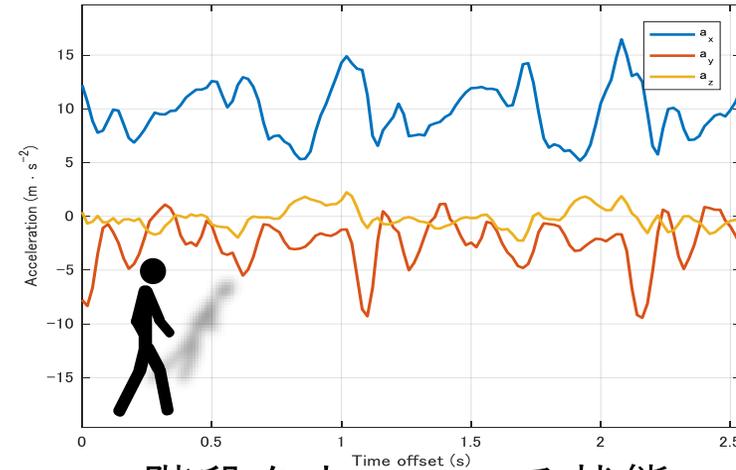
直立の状態



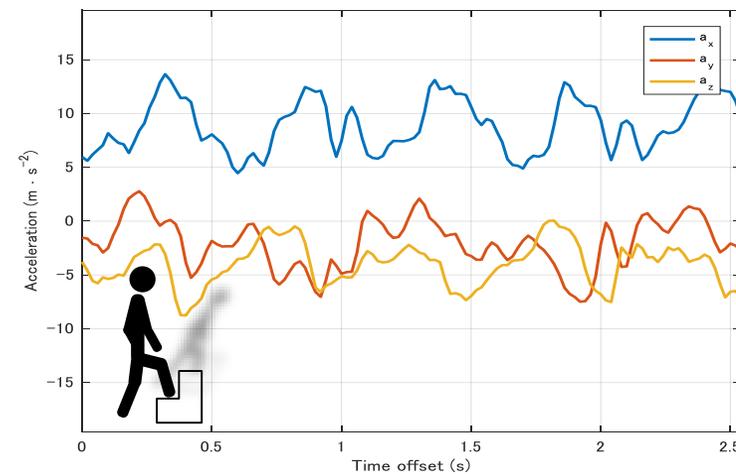
寝転んだ状態



歩いている状態

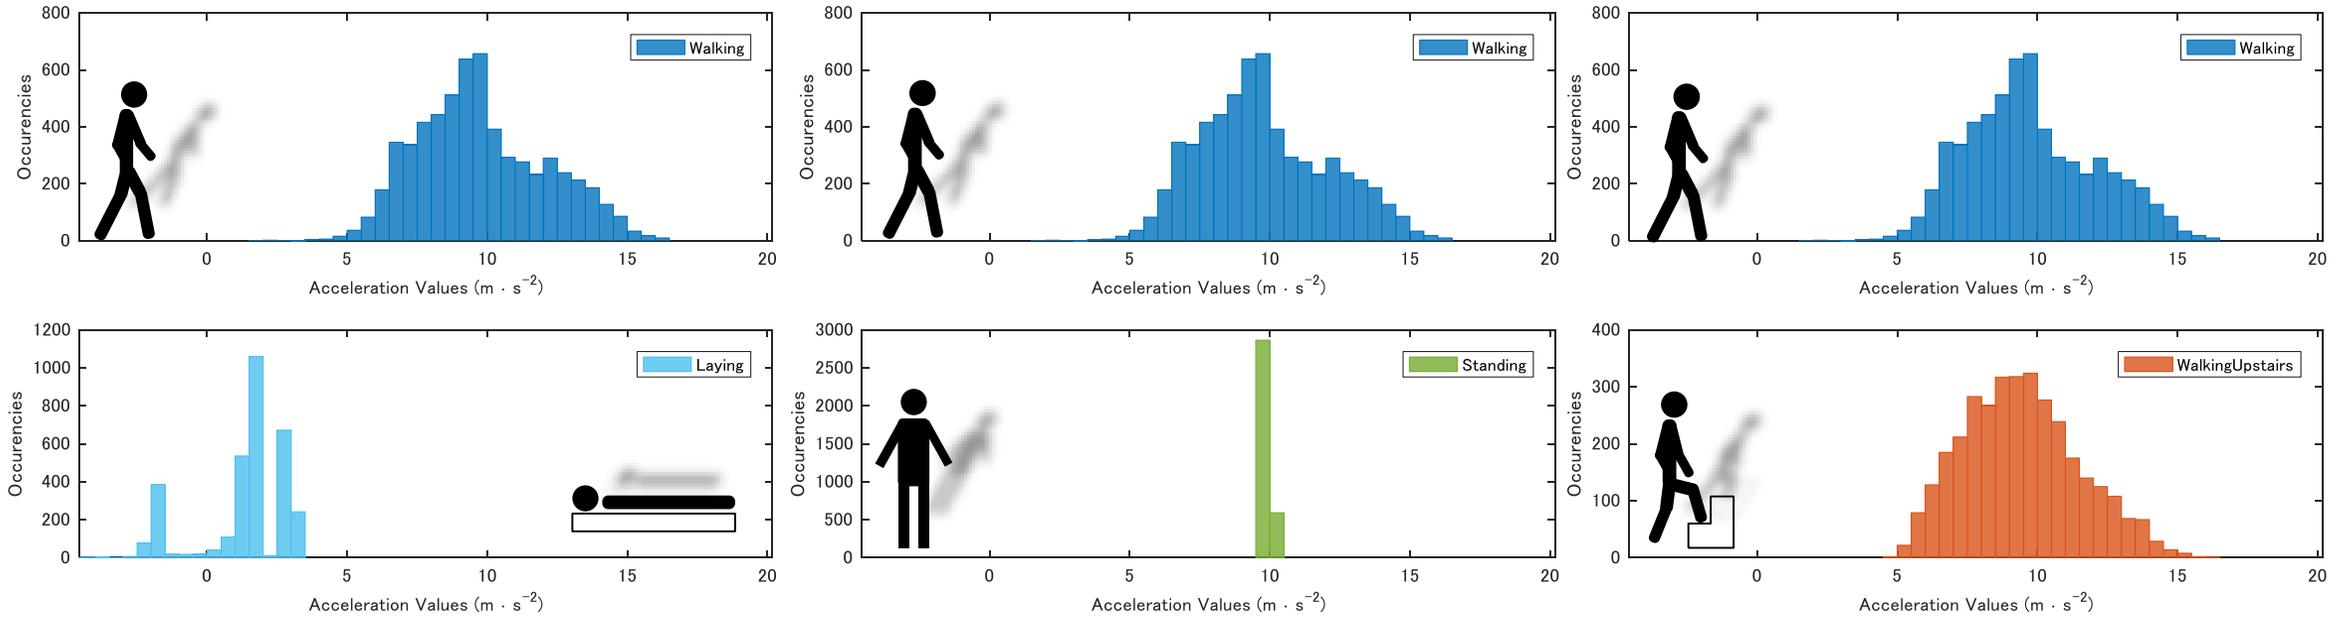


階段を上っている状態



加速度センサー情報による人の活動認識

同じデータでも分類対象によっても最適な特徴量は様々



歩く vs. 寝る



平均値で識別

歩く vs. 立つ



標準偏差で識別

歩く vs. 階段を上る



???

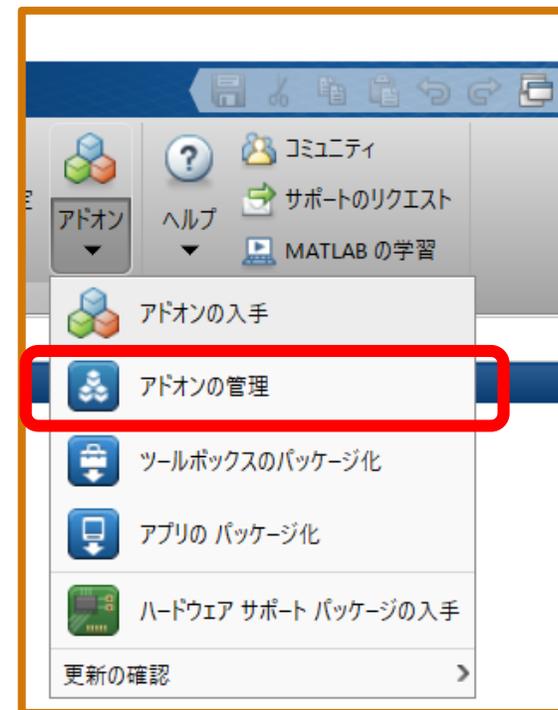
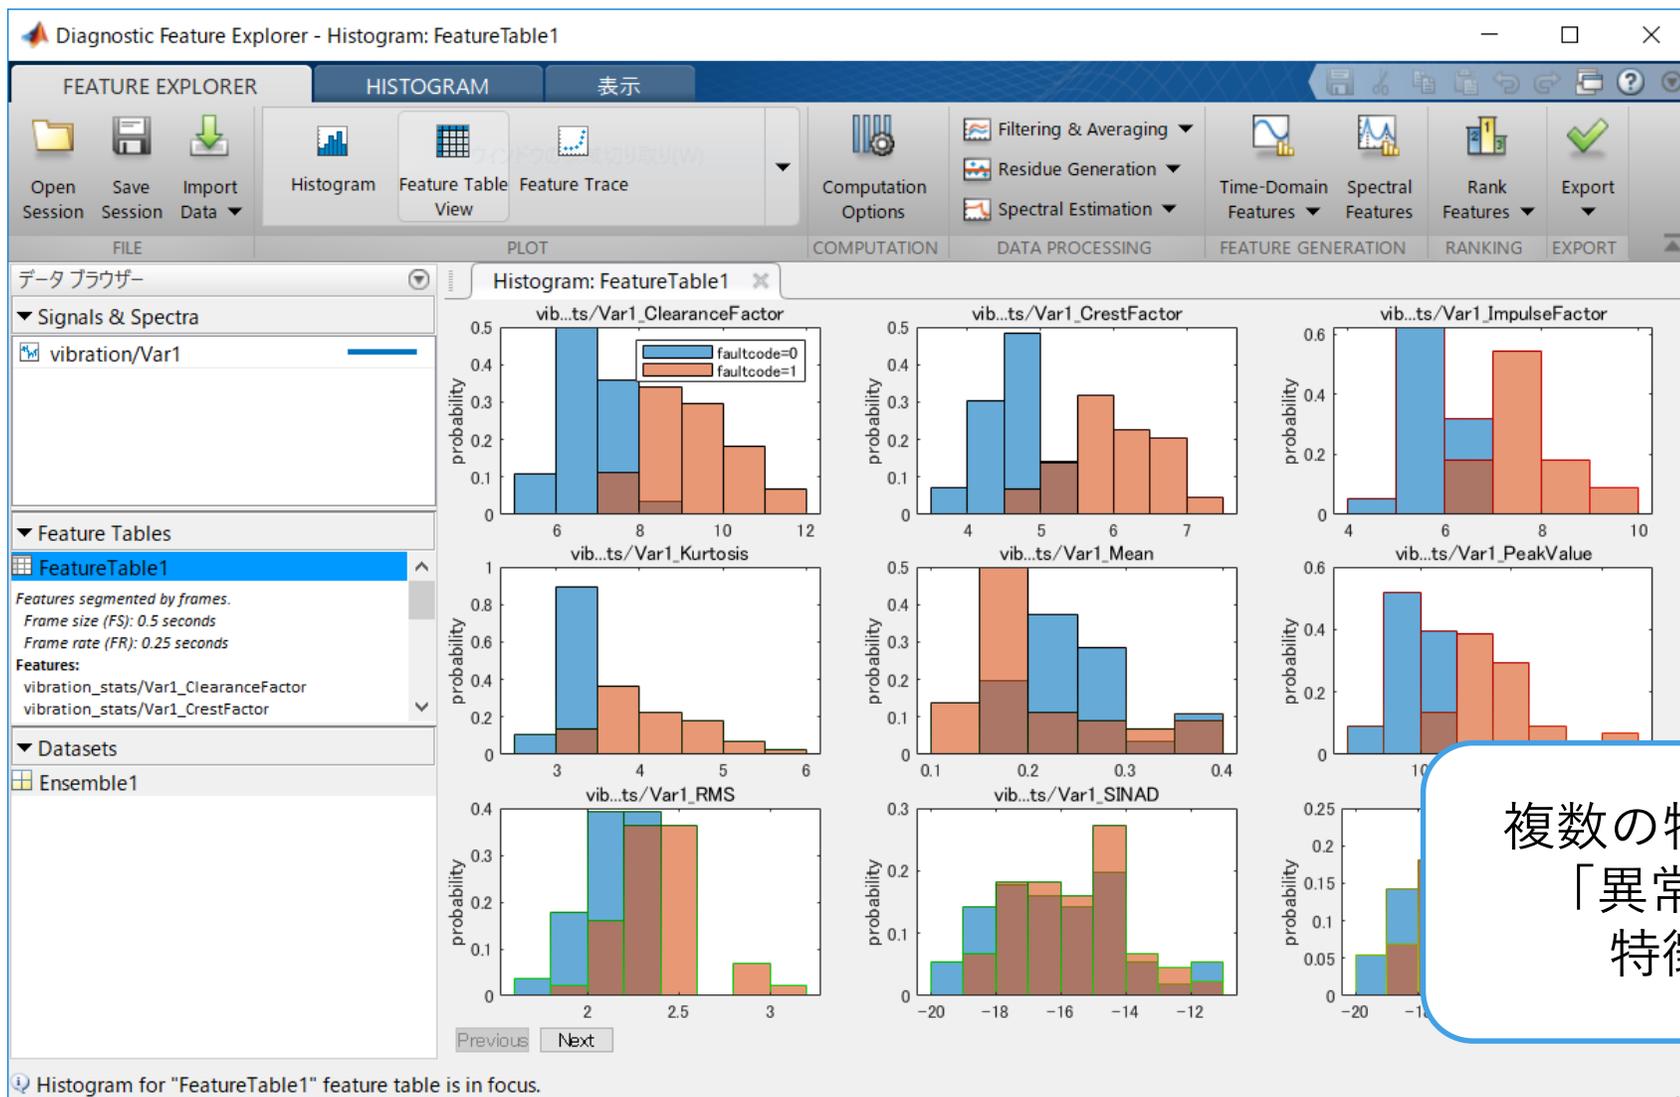
Diagnostic Feature Explorer

特徴量選択を簡単に実施するアプリ



注：R2018bではSupport Package としてのリリース

[File Exchange](#) で検索もしくは【アドオン管理】からDL

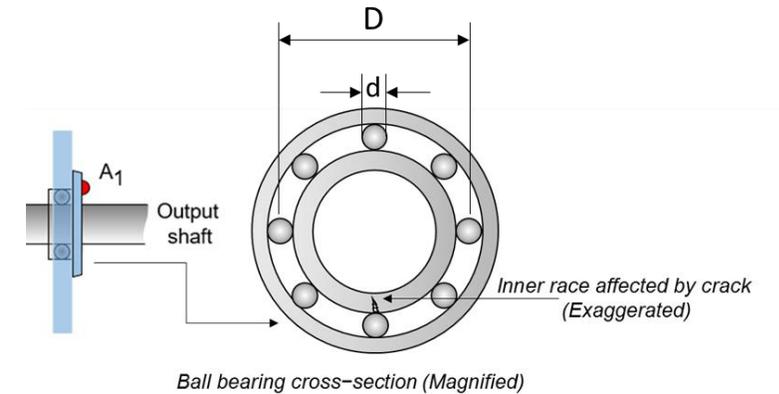


複数の特徴量を算出・可視化し
「異常/正常」を区別できる
特徴量の特定を容易に

アジェンダ

生産技術向け故障予測・予知保全

- 故障予測システムの開発事例
- 故障予測を可能にする特徴量とは
- Demo：風力タービンの故障予測
- まとめ



Demo : 風力タービンの故障予測アルゴリズム開発

[詳細URL](#)

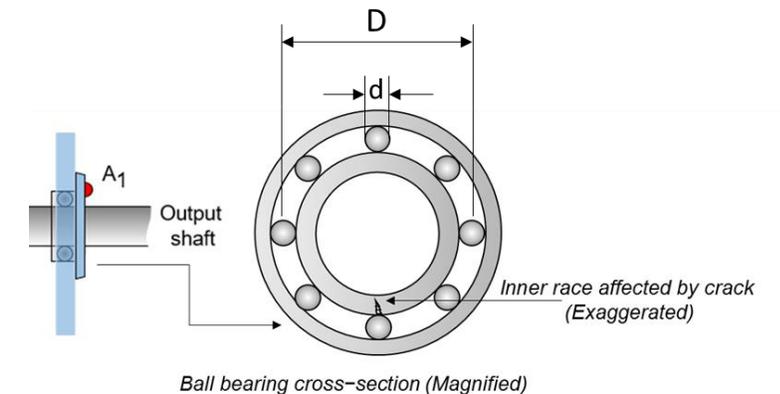
シャフトに発生する振動データ (加速度)

- サンプリング周波数 : 約100kHz
- 1日6秒間 x 50日分

故障 : ベアリングの内側にひび割れ

ゴール

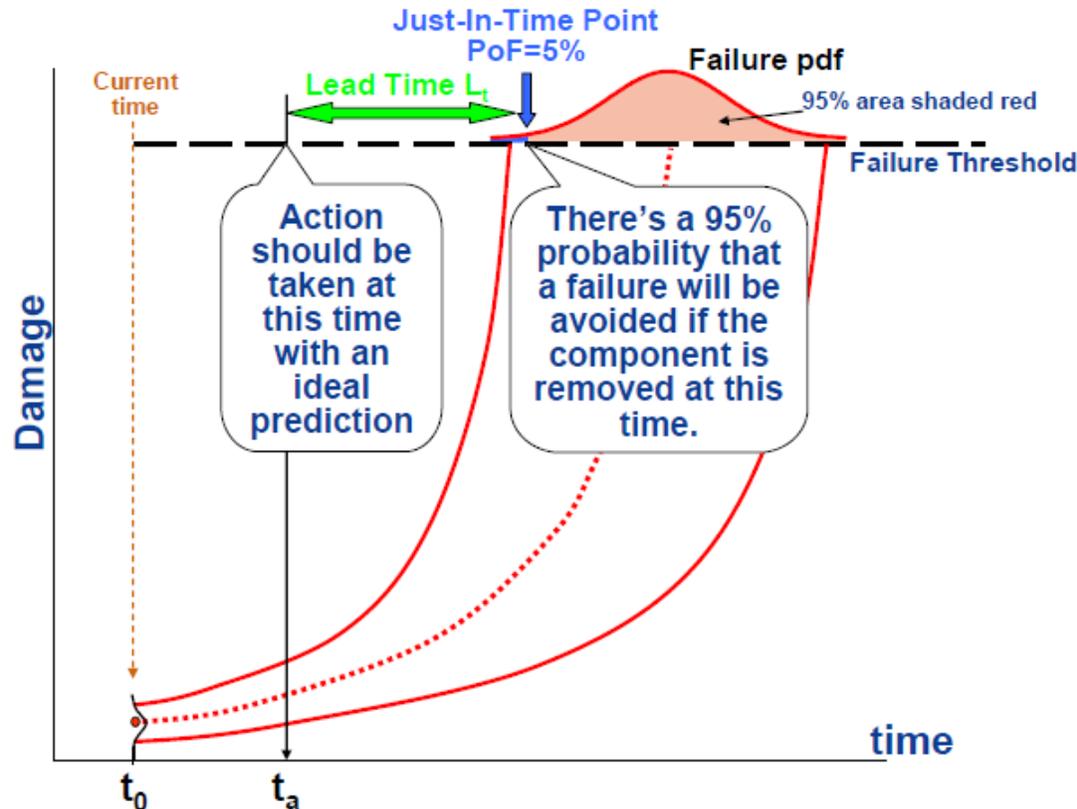
故障発生までの時間 (機器の寿命/RUL) 予測



データ元 : <http://data-acoustics.com/measurements/bearing-faults/bearing-3/>

Bechhoefer, Eric, Brandon Van Hecke, and David He. "Processing for improved spectral analysis." *Annual Conference of the Prognostics and Health Management Society, New Orleans, LA, Oct. 2013.*

なぜ確率分布が必要か？



予測の平均値：50%の確率で既に故障

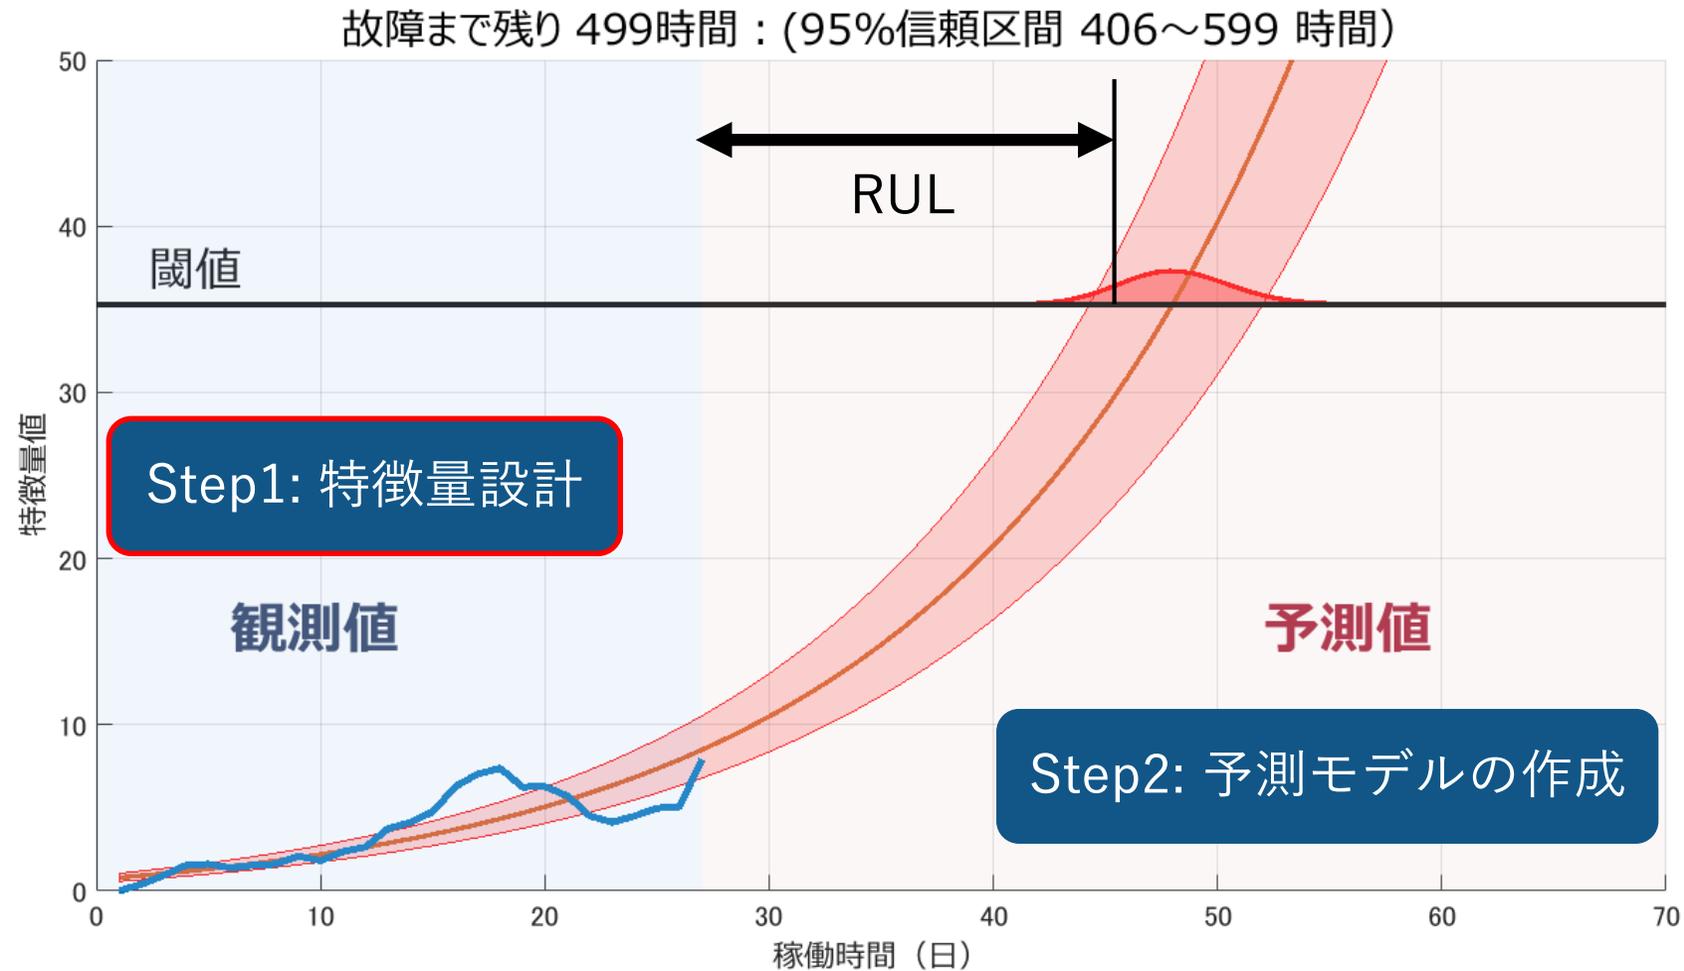
考慮すべき点

許容可能リスク

- 5%は故障を回避できないリスク？
- 1%は故障を回避できないリスク？

故障を回避できなかった場合の
“コスト”との兼ね合いで決定

Demo : 風力タービンの故障予測アルゴリズム開発

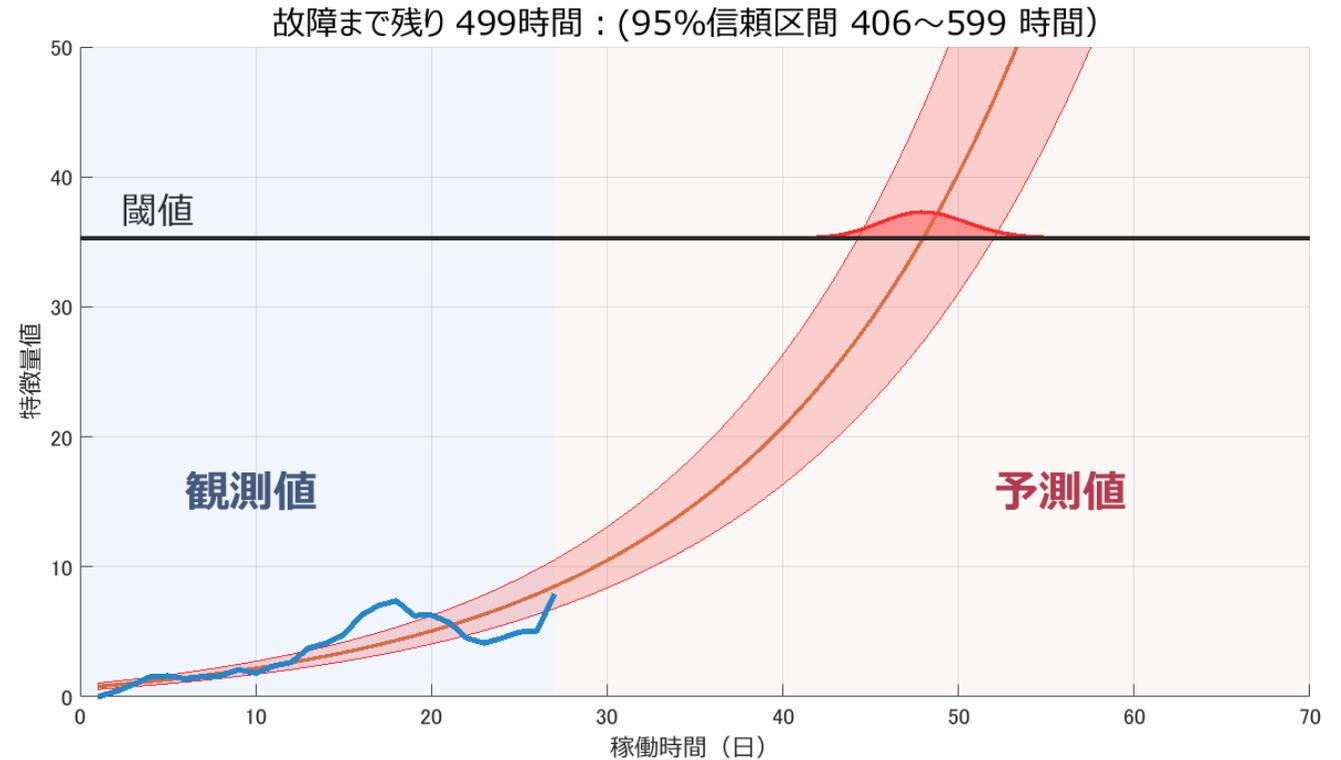


Demo : 風力タービンの故障予測アルゴリズム開発

Step1: 特徴量設計

Goal: 劣化の進行状況を示す特徴量の特定

- 1: 特徴量を複数算出
- 2: 特徴量の良さを定量化
- 3: 特徴量の選択・生成



Demo : 風力タービンの故障予測アルゴリズム開発

Step1-1: 15種類の特徴量を算出

```
while hasdata(hsbearing)
    data = read(hsbearing);
    v = data.vibration{1};
    SK = data.SpectralKurtosis{1}.SK;

    % 時間領域における各種特徴量(一部)
    features.Mean = mean(v);
    features.Std = std(v);
    features.Skewness = skewness(v);
    features.Kurtosis = kurtosis(v);

    % スペクトル尖度に関する特徴量(一部)
    features.SKMean = mean(SK);

    % 計算結果をファイルに追記
    writeToLastMemberRead(hsbearing, features);
end
```

【補足】 算出した15種類の特徴量

Demo：風力タービンの故障予測アルゴリズム開発

1. Mean：平均値
2. Std：標準偏差
3. Skewness (歪度)：分布の非対称性を示す指標
4. Kurtosis (尖度)：分布の鋭さを示す指標
5. Peak2peak：最大値と最小値の差
6. Rms：二乗和の平方根 (実効値)

$$V_{arg} = \frac{1}{N} \sum_{i=1}^N x_i$$

$$V_{rms} = \sqrt{\frac{1}{N} \sum_{i=1}^N |x_i|^2}$$

$$V_{skw} = \frac{\frac{1}{N} \sum_{i=1}^N |x_i - V_{arg}|^3}{\left(\sqrt{\frac{1}{N} \sum_{i=1}^N |x_i - V_{arg}|^2} \right)^3}$$

$$V_{kurt} = \frac{\frac{1}{N} \sum_{i=1}^N |x_i - V_{arg}|^4}{\left(\sqrt{\frac{1}{N} \sum_{i=1}^N |x_i - V_{arg}|^2} \right)^4}$$

【補足】算出した15種類の特徴量

Demo：風力タービンの故障予測アルゴリズム開発

7. Crestfactor（波高率）：ピーク値/実効値
8. Shapefactor（波形率）：実効値/平均値
9. Impulsefactor（インパルス係数）：
10. Marginfactor（マージン係数）：
11. Energy：二乗和
12. Skmean：平均値（スペクトル尖度）
13. SKStd：標準偏差（スペクトル尖度）
14. SKSkewness：歪度（スペクトル尖度）
15. SKKurtosis：尖度（スペクトル尖度）

$$V_{crf} = \frac{V_{pv}}{V_{rms}}$$

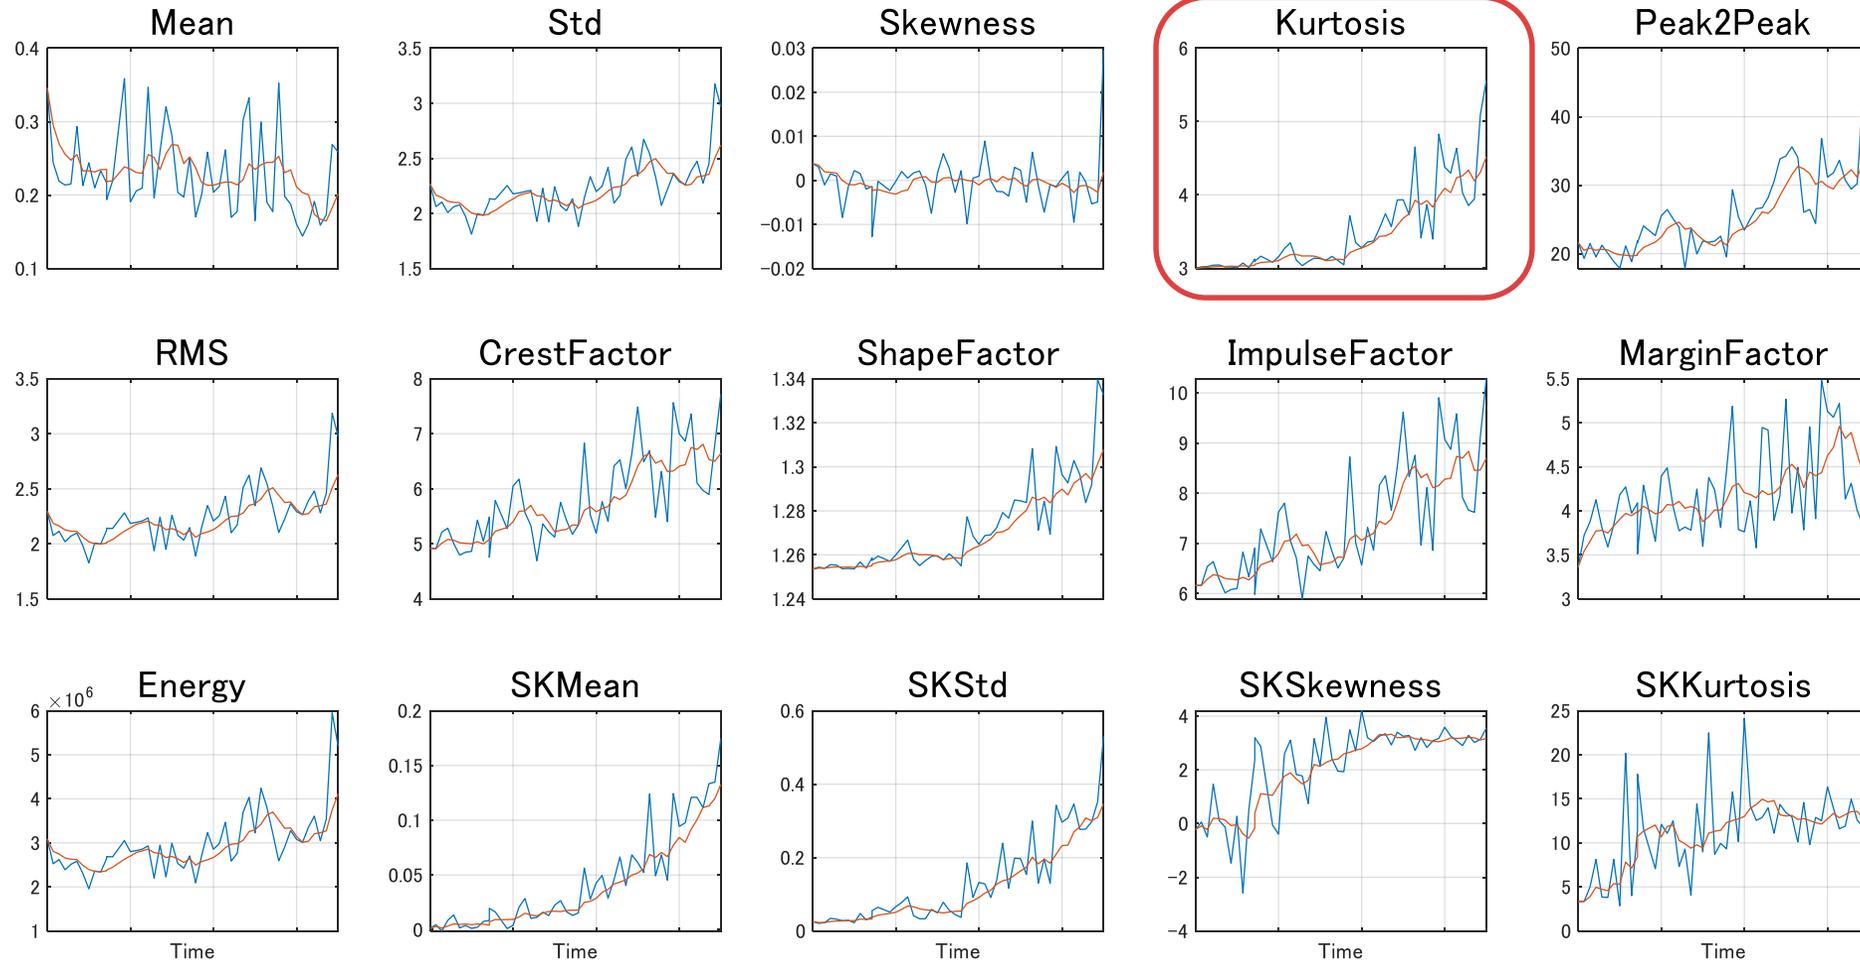
$$V_{shf} = \frac{V_{rms}}{V_{arg}}$$

$$V_{impf} = \frac{V_{pv}}{\frac{1}{N} \sum_{i=1}^N |x_i|}$$

$$V_{mgn} = \frac{V_{pv}}{\left(\frac{1}{N} \sum_{i=1}^N \sqrt{|x_i|}\right)^2}$$

Demo : 風力タービンの故障予測アルゴリズム開発

Step1-1: 15種類の特徴量を算出



Demo : 風力タービンの故障予測アルゴリズム開発

Step1: 特徴量設計

Goal: 劣化の進行状況を示す特徴量の特定

1: 15種類の特徴量を算出

2: 特徴量の良さを定量化

- Monotonicity : 単調増加度合い
- Trendability : 共通する増加傾向の有無
- Prognosability : 予測のしやすさ

[出典] Coble, Jamie Baalis. "Merging data sources to predict remaining useful life—an automated method to identify prognostic parameters." (2010).

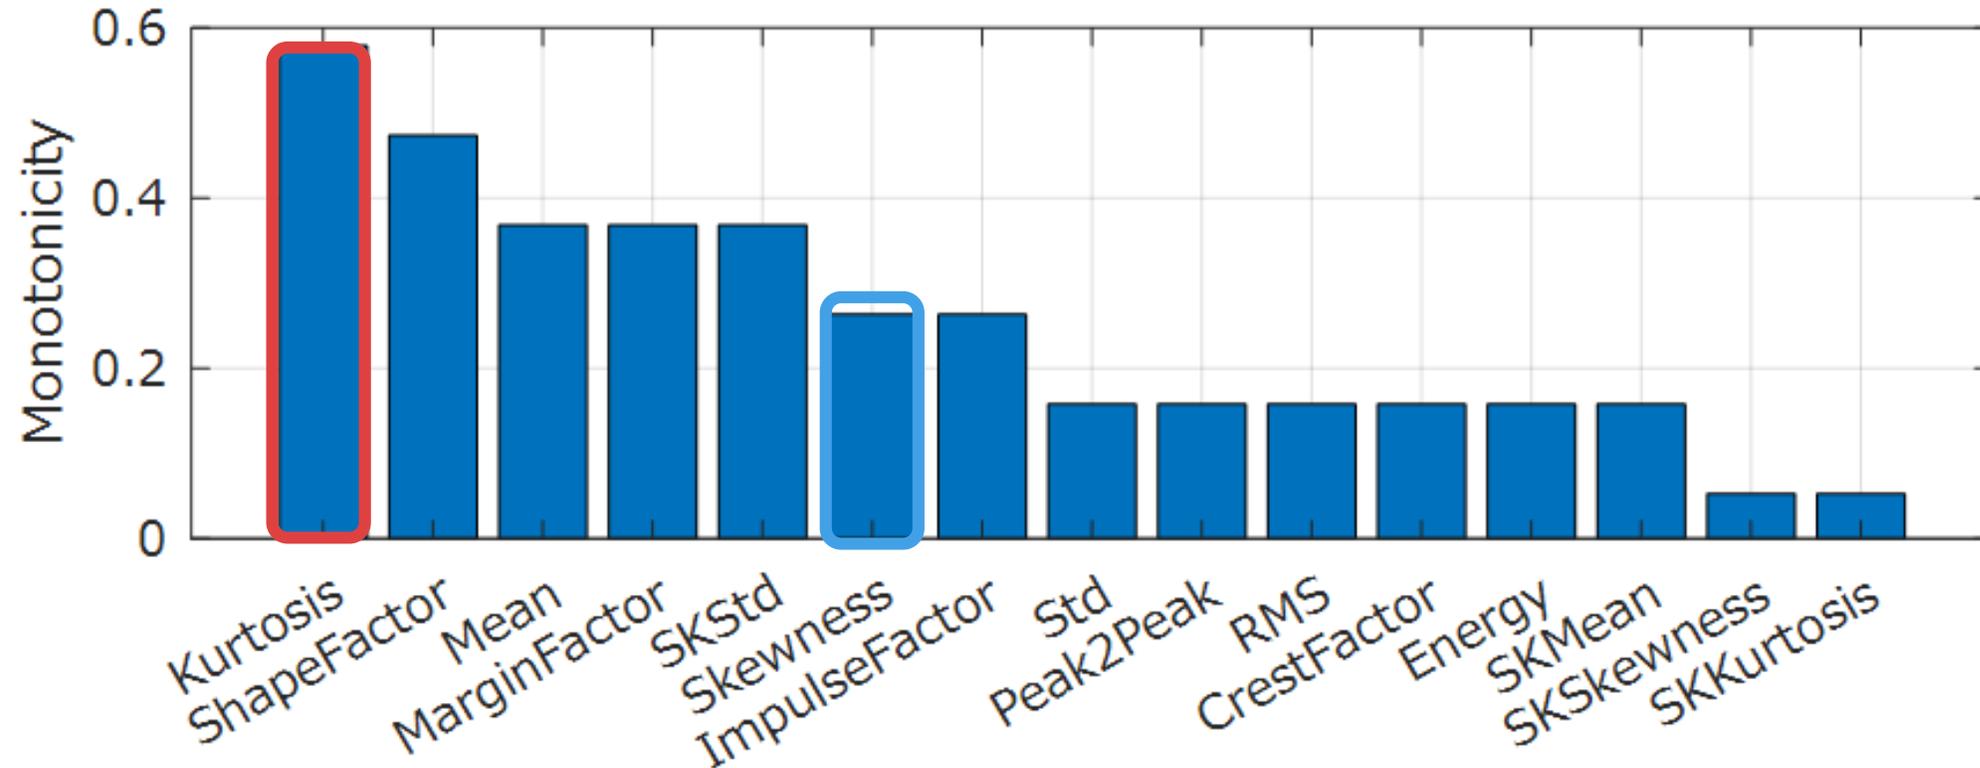
3: 特徴量の選択・生成

Demo : 風力タービンの故障予測アルゴリズム開発

Step1-2: 特徴量の良さを定量化

Monotonicity : 単調増加度合い

```
function m = monotonicity(x)
% Compute monotonicity given a vector x
n = length(x);
dx = diff(x);
m = abs(sum(dx>0) - sum(dx<0))/(n-1);
end
```



Demo：風力タービンの故障予測アルゴリズム開発

Step1-3: 特徴量の選択・生成

Goal: 劣化の進行状況を示す特徴量の特定

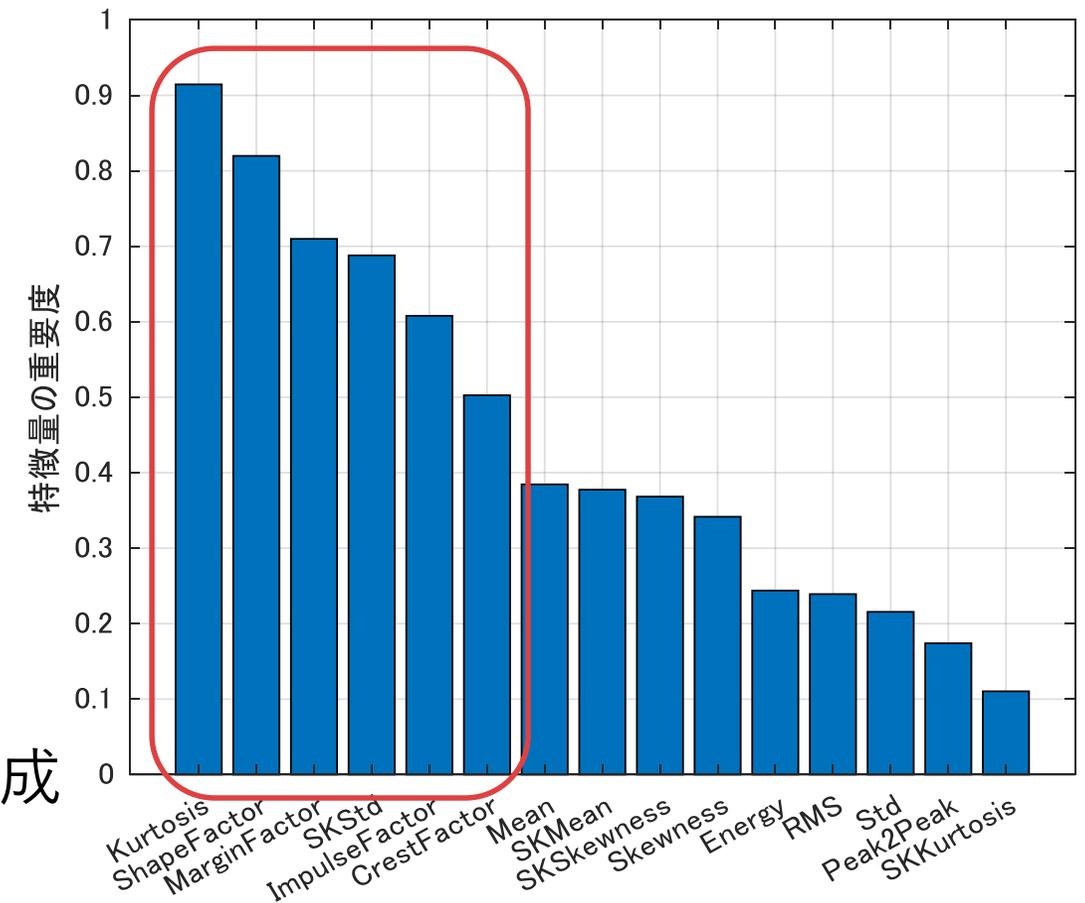
1: 15種類の特徴量を算出

2: 特徴量の良さを定量化

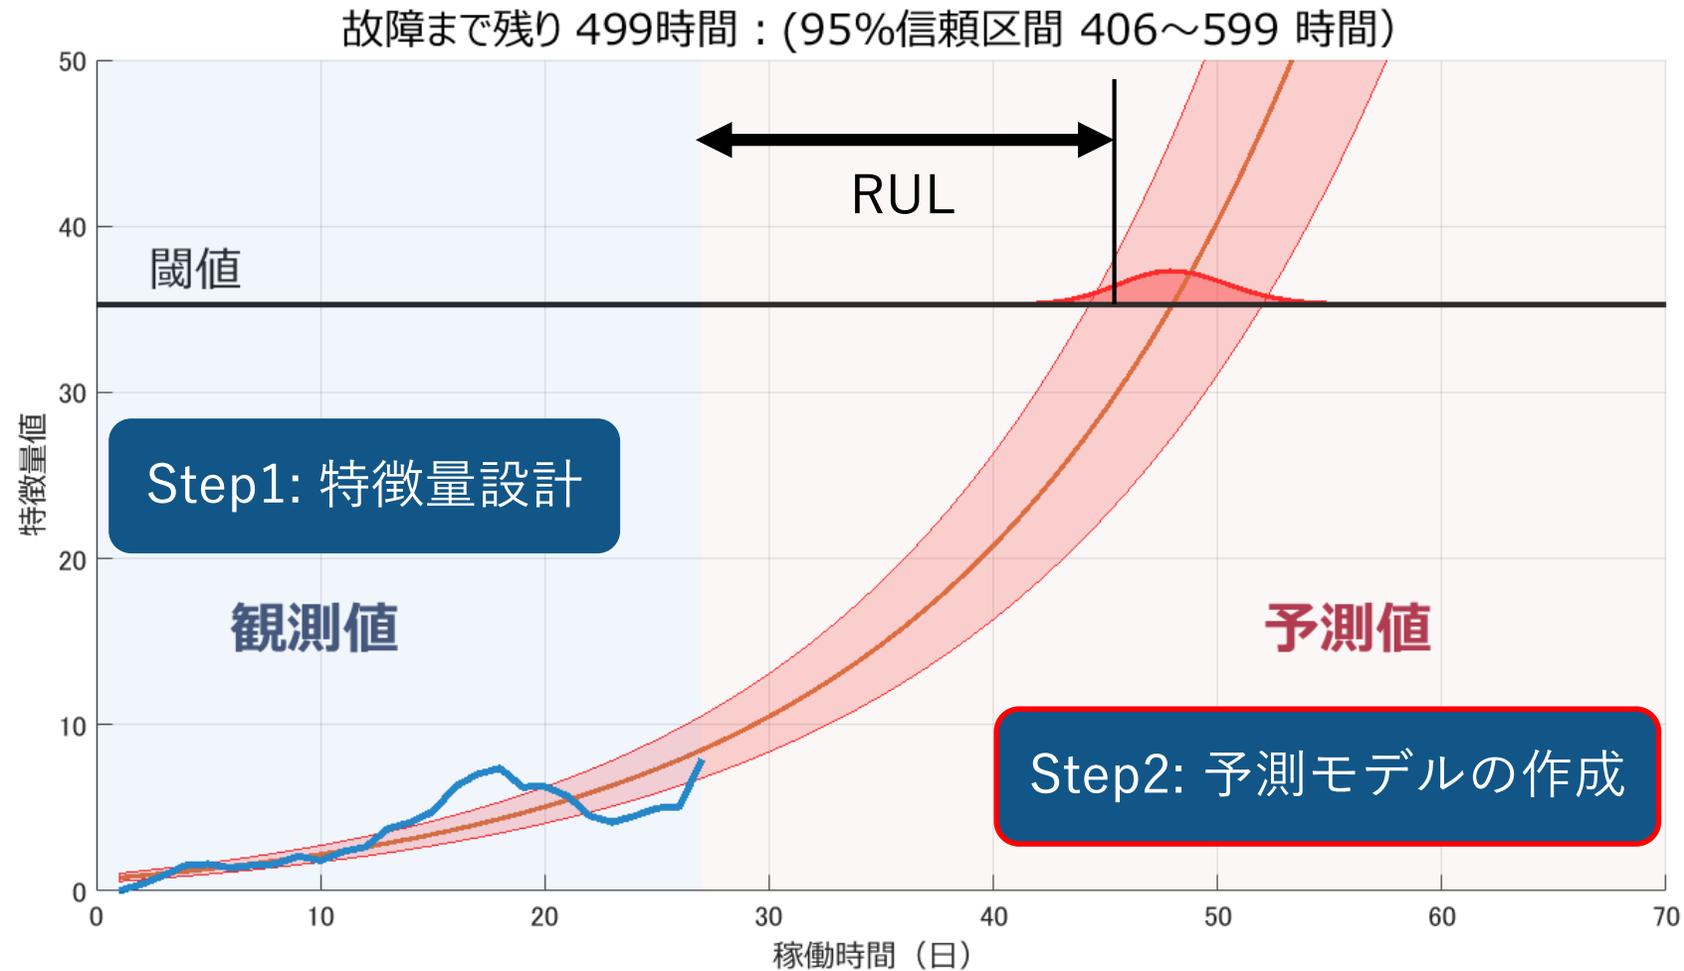
3: 特徴量の選択・生成

- もっとも”よい”特徴量だけを使用
- ある程度“よい“を融合して新変数を作成
(例：主成分分析)

特徴量の“よさ”の定量化

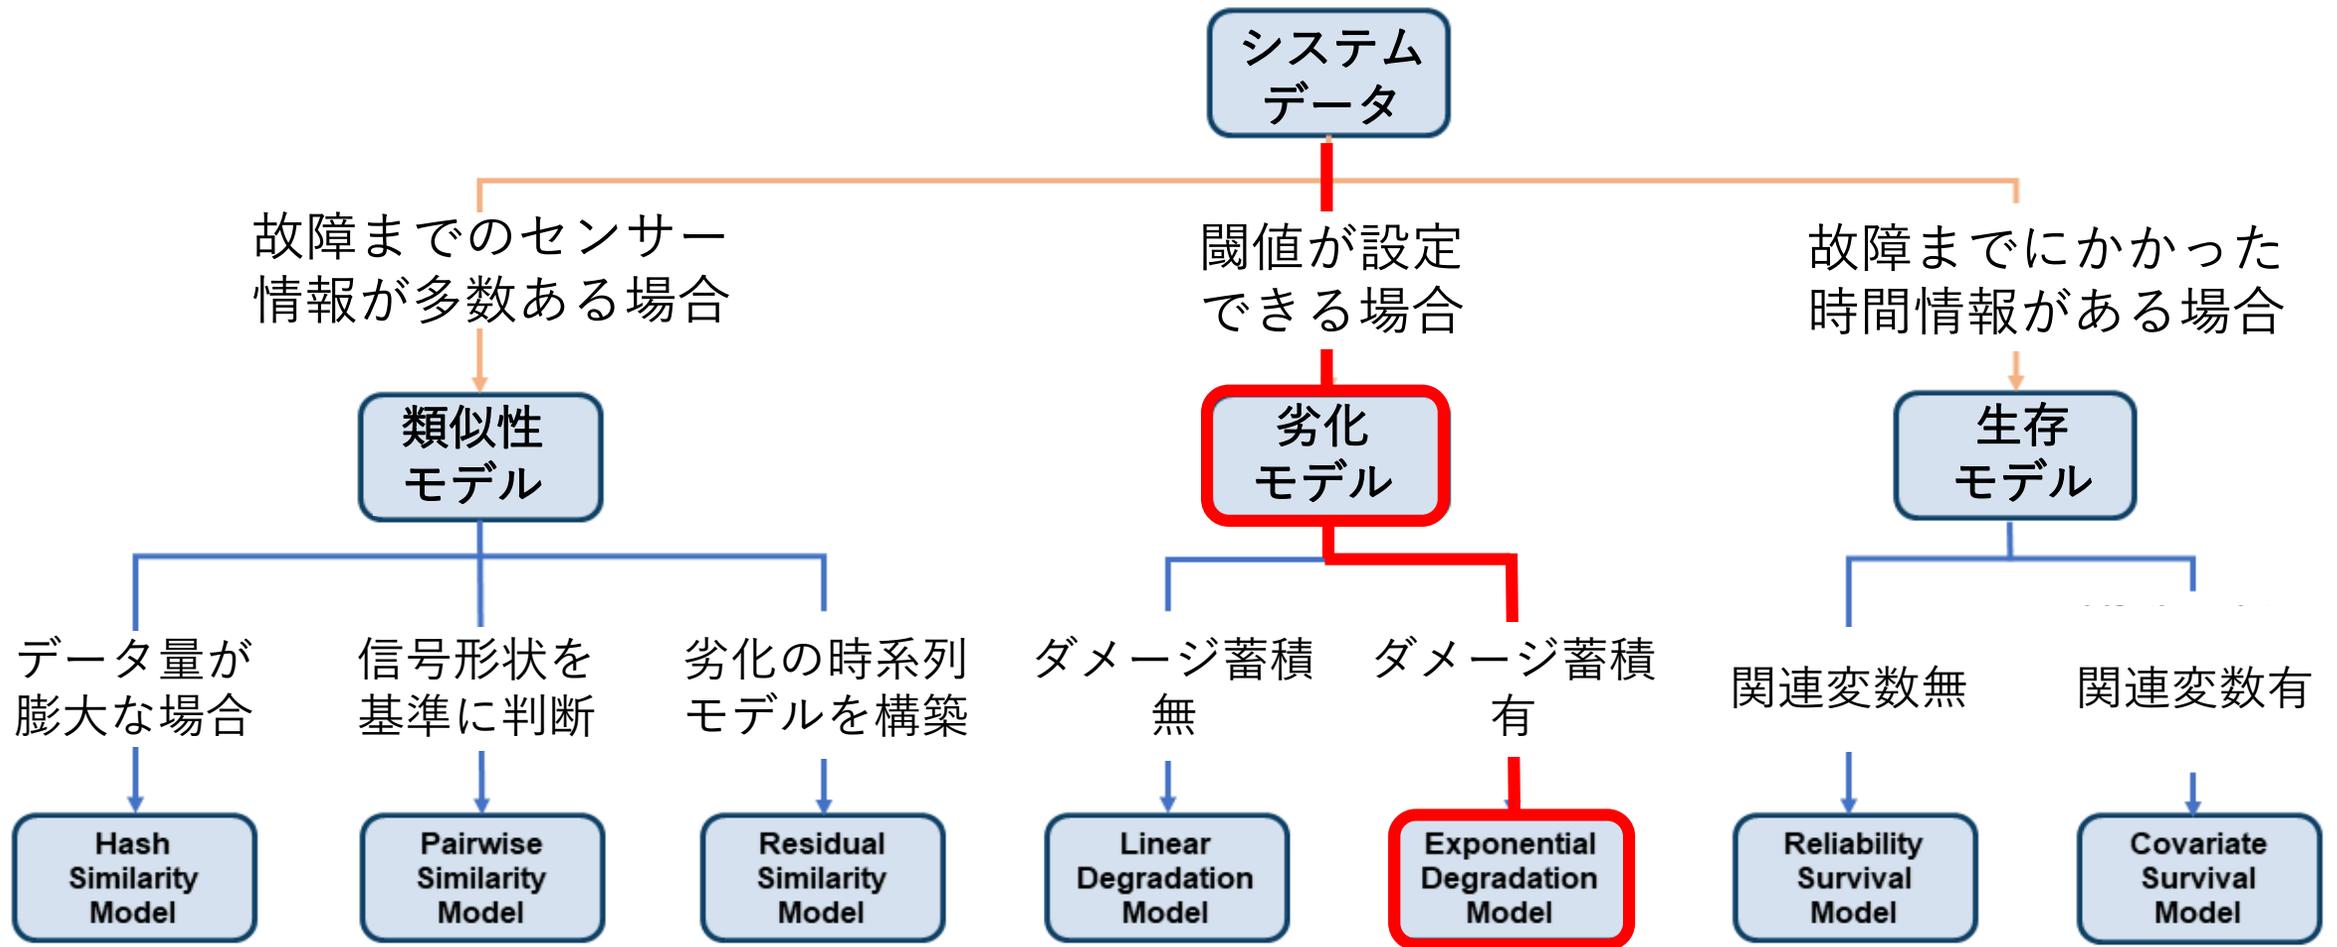


Demo : 風力タービンの故障予測アルゴリズム開発



機器の寿命 (RUL) を予測する 7つのモデル

各モデルの使い分けの指針



今回はこれを適用

Demo：風力タービンの故障予測アルゴリズム開発

Step2: 予測モデル作成

% 指数劣化モデルの作成

```
mdl = exponentialDegradationModel;
```

$$h(t) = \phi + \theta \exp\left(\beta t + \epsilon - \frac{\sigma^2}{2}\right)$$

以下のケースで有効

- 注目する閾値を超えるまでの時間を予測
- ダメージ蓄積が考えられる

```
for currentDay = 1:totalDay
```

% 事後確率分布の更新

```
update(mdl, [currentDay healthIndicator(currentDay)])
```

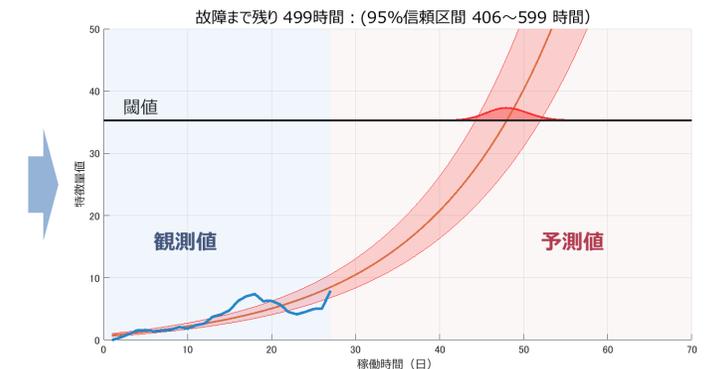
% RULの予測

```
[estRUL, CIRUL, pdfRUL] = predictRUL(mdl, ...  
    [currentDay healthIndicator(currentDay)], ...  
    threshold);
```

```
end
```

逐次モデルを更新

現時点での観測データ・閾値をもとに予測



【補足】 機器の寿命 (RUL) を予測するモデル

状況に応じた7つのモデルを提供: Predictive Maintenance Toolbox

類似性モデル: 過去の実績データから類似の傾向を持つケースを探索

- [hashSimilarityModel](#): 時系列データの統計量 (平均・最大値など) から類似性を算出
- [pairwiseSimilarityModel](#): 時系列データの"距離" (相関 or [dtw](#)) から類似性を直接算出
- [residualSimilarityModel](#): 時系列モデルを構築し、モデルからの差異から類似性を算出

劣化モデル: 特定の変数が閾値を超える時期を予測

- [linearDegradationModel](#): 線形モデル $y_t = \Phi + \theta_t * t + \epsilon_t \quad \theta_t \sim N(\mu_t, \sigma_t^2)$
- [exponentialDegradationModel](#): 指数関数モデル $y_t = \Phi + \theta_t \exp(\beta_t * t + \epsilon_t - \frac{\sigma^2}{2} t) + \epsilon_t$

生存モデル: 寿命データを確率分布にフィッティング

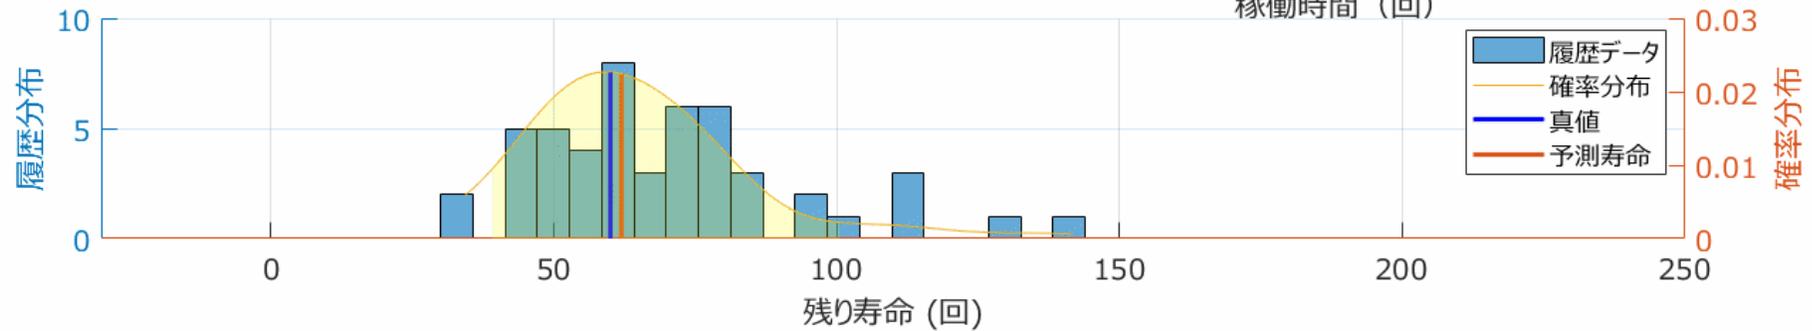
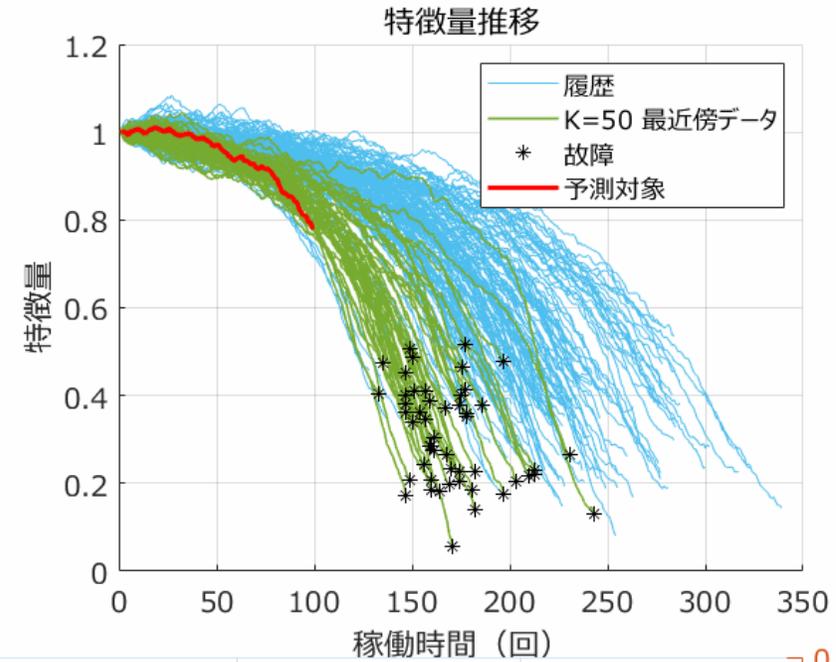
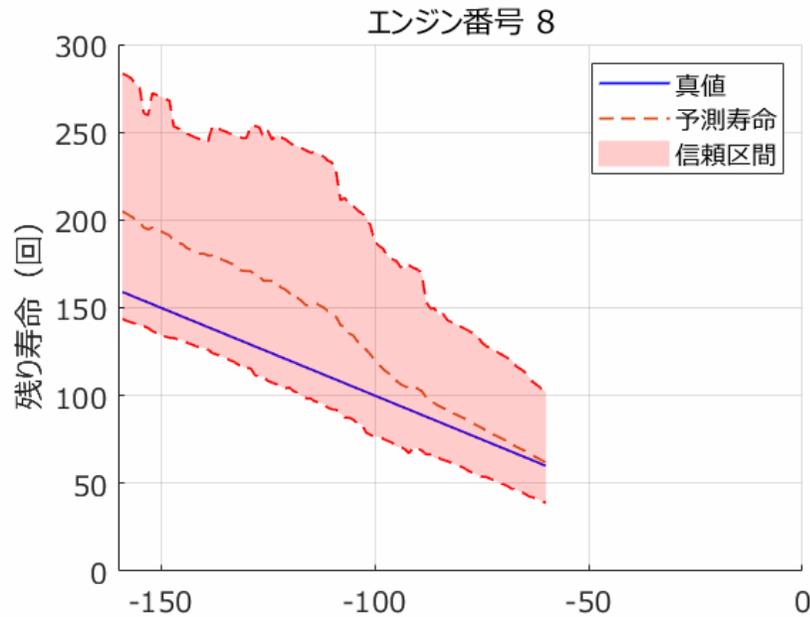
- [reliabilitySurvivalModel](#): 環境変数がない場合
- [covariateSurvivalModel](#): 環境変数を活用する場合

モデルの使い方

[predictRUL](#) で予測

[update](#) でモデルを随時更新

【補足】 類似性モデルによる寿命予測例



【補足】 Predictive Maintenance Toolbox の特徴量抽出機能

- データ発生源のシステム変動を定量化
 - [lyapunovExponent](#) : 相空間における軌道が離れていく度合いを表す量
 - [approximateEntropy](#) : 時系列データの秩序性を定量化する値
 - [correlationDimension](#) : 相空間における次元数
- 周波数領域の時間変化をモーメント(平均, 分散, 歪度, 尖度)で定量化
 - 時間周波数モーメント (time-frequency moment)
 - [tfsmoment](#) : Conditional spectral moment
 - [tftmoment](#) : Conditional temporal moment
 - [tfmoment](#) : Joint time-frequency moment

- 異常を早期にとらえることができる可能性
- ベアリングやギアから発生する振動や音データの解析向き

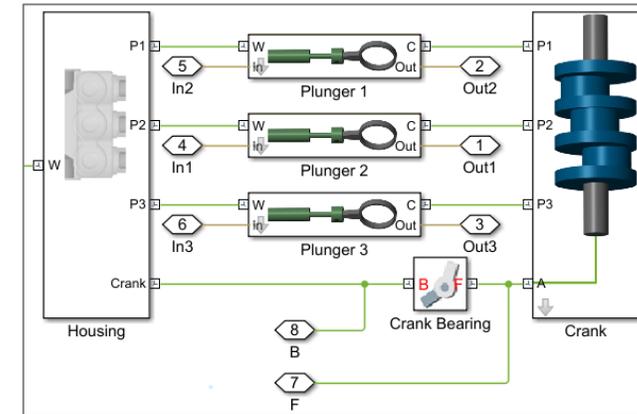
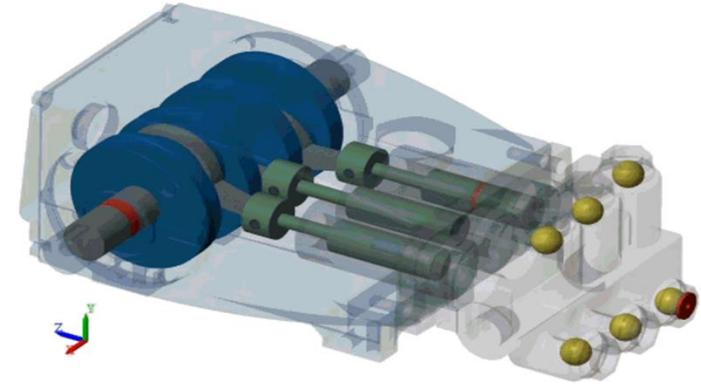
[1] Caesarendra, W et al. 2013 "An application of nonlinear feature extraction-A case study for low speed slewing bearing condition monitoring and prognosis." *IEEE/ASME International Conference on Advanced Intelligent Mechatronics: Mechatronics for Human Wellbeing, AIM 2013*.1713-1718. 10.1109/AIM.2013.6584344.

[2] Loughlin, P et al. 2000 "Conditional Moment Analysis of Transients with Application to Helicopter Fault Data." *Mechanical Systems and Signal Processing*

アジェンダ

生産技術向け故障予測・予知保全

- 故障予測システムの開発事例
- 故障予測を可能にする特徴量とは
- Demo：風力タービンの故障予測
- まとめ



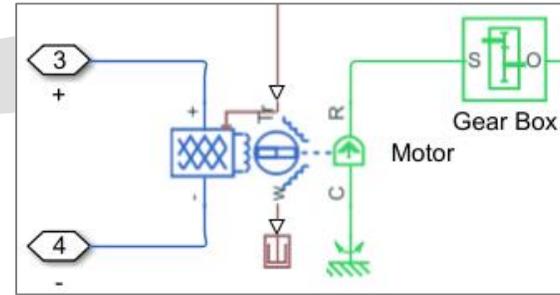
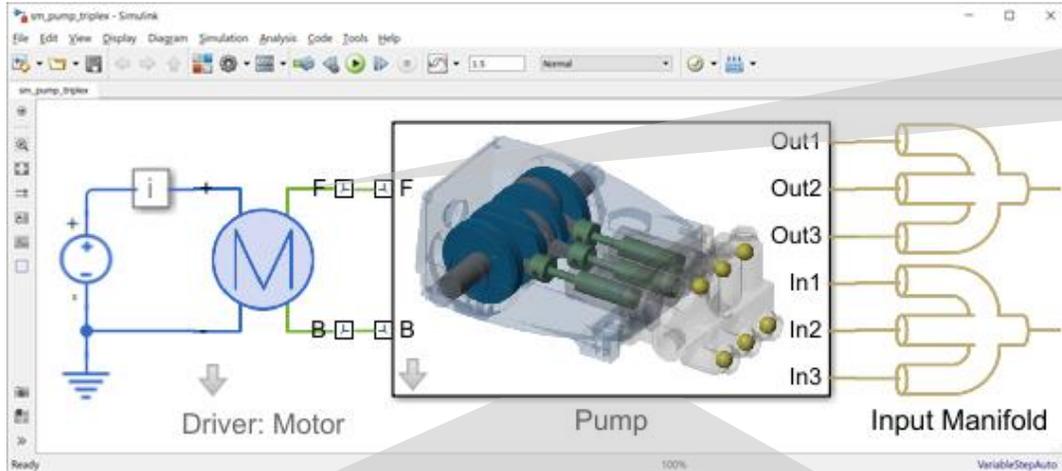
予知保全で直面する4 課題

- ✓ 十分な量のデータがない
- ✓ 十分な量の故障データがない
- ✓ 故障予測の方法が分からない
- ✓ 予知保全アルゴリズムの構築方法が分からない



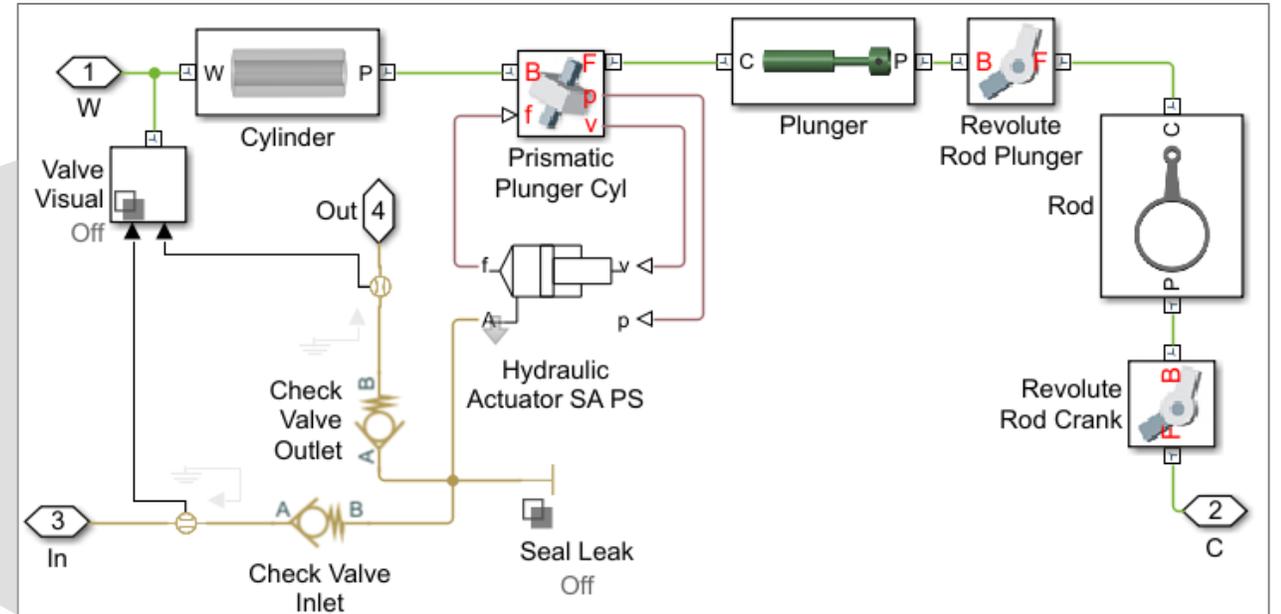
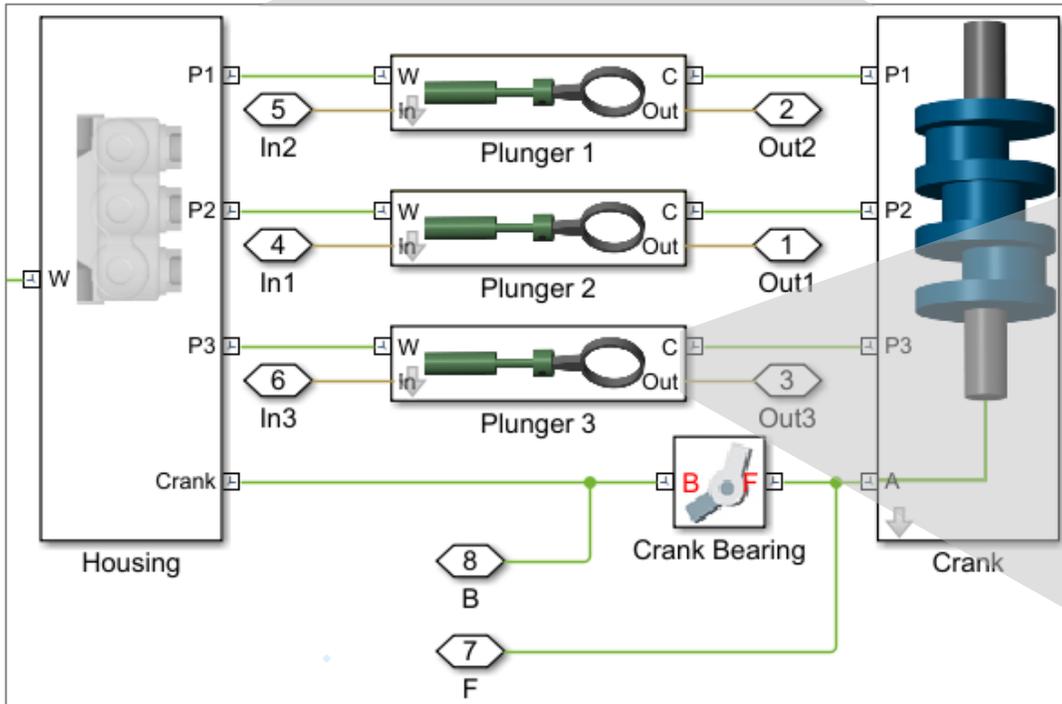
こちらからDL：[予知保全で直面しやすい4つの課題とその対処法](#)

物理モデルを使用した故障データの作成：物理法則に基づく方法



メリット
 ✓ 本質を捉えたモデル構築

デメリット
 ✓ モデル導出・構築の労力



Key Takeaways

- 予知保全における課題
 - 特徴量選択をはじめ、多くの試行錯誤が求められる
- Predictive Maintenance Toolbox で効率的にアルゴリズム開発
 - 複数の予測モデルと特徴量抽出機能
 - アプリ“Diagnostics Feature Explorer”
- 故障予測システムを手軽に構築できるMATLABプラットフォーム
 - 物理モデルからアルゴリズム開発・実装までカバー

デモで使用した製品



[MATLAB / Simulink](#)

R2018b

[Predictive Maintenance Toolbox](#)

[Statistics and Machine Learning Toolbox™](#)

[Signal Processing Toolbox™](#)

[System Identification Toolbox™](#)



【補足】具体的な使い方について知るには？ 関連Webセミナー

MATLABを使った予知保全・故障予測

ターボファンエンジンのデータを使って
故障時期を予測する簡単なフローを紹介

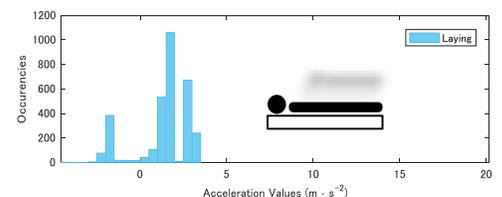
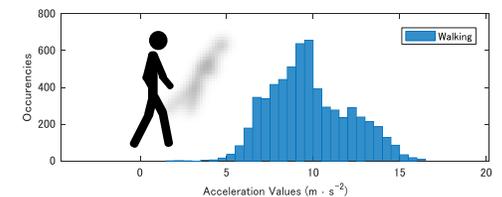
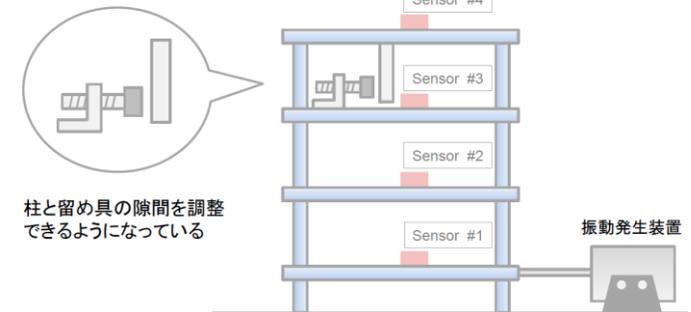
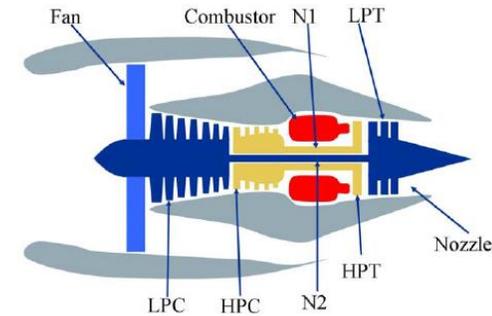
センサーデータ解析と機械学習

構造ヘルスマニタリングで利用される振動データを題材に

- 時系列信号からの特徴抽出、PCAによる次元削減
- 分類木によるデータの分類、1-クラス SVM による異常検出

機械学習のための信号処理

「センサーデータ解析による人の行動認識」を題材として、
特徴量の抽出方法を、各種信号処理機能と合わせて紹介



[1] <http://jp.mathworks.com/videos/predictive-maintenance-with-matlab-a-prognostics-case-study-121138.html>

[2] <http://jp.mathworks.com/videos/sensor-data-analysis-and-machine-learning-anomaly-detection-using-vibration-data-100241.html>

[3] <http://jp.mathworks.com/videos/signal-processing-for-machine-learning-119299.html>

【補足】異常検知・予知保全についてもっと知るには？

ホワイトペーパー

ホワイトペーパー

予知保全で直面しやすい4つの課題と
その対処法



予知保全システム構築における4つの課題
とその対処方法をご紹介します

こちらからDL：[予知保全で直面しやすい4つの課題とその対処法](#)



予知保全システム構築事例をご紹介します

こちらからDL：[実例に学ぶ予知保全向けデータ活用](#)



ホワイトペーパー

実例に学ぶ予知保全向けデータ活用

～MATLABを使った故障予測で一步先のメンテナンス～



【補足】異常検知・予知保全についてもっと知るには？

Discovery page



予知保全

サイト内検索



予知保全とは

機器に取り付けたセンサーから取得したデータを基に故障や劣化を検知し、故障が発生する前の適切なタイミングでメンテナンスを行うことを、予知保全 (Predictive Maintenance) と呼びます。

機器のメンテナンスといえば、故障が発生した後に実施する事後保全 (Reactive Maintenance) や、一定期間経過した時にメンテナンスを行う予防保全 (Preventive Maintenance) が一般的です。予防保全では走行距離 3000km または 3ヶ月毎に実施する自動車のオイル交換など、状態に関わらずメンテナンスが行われる一方、予知保全は状態監視保全や状態基準保全 (Condition Based Maintenance) とも呼ばれ、機器の状態に応じてメンテナンス時期を判断します。余計なメンテナンスを避ける事によるコスト削減だけでなく、予期しない突発的な故障を避けられ安全性の向上にも繋がると期待されています。

「予知保全」で検索



MATLABを使っ
全・故障予測

異常検知



機械学習を用い
セスのヘルスマ
モマ知保へ

異常検知とは

異常検知 (Anomaly detection) とは、データの中から異常な状態、すなわち通常のパターンとは異なる挙動を検出することをいいます。「異常」はアプリケーションや状況によって、外れ値 (Outlier)、変化点 (Change point)、逸脱 (Deviation)、誤作動 (Fault)、侵入 (Intrusion)、詐欺 (Fraud) などと呼ばれます。

異常検知には専門家の目視による古典的な方法も有効ですが、ここでは多くの変数からなる複雑なデータからでも、自動でかつ早期に異常を見つけ出すことが期待できる機械学習を用いた統計的手法をご紹介します。

データ解析を応用した異常検知の代表的な利点

- 診断 (Diagnostic) : 異常を自動で診断することにより人的工数を削減。

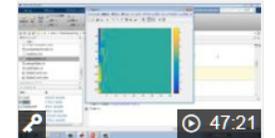
<https://jp.mathworks.com/discovery/predictive-maintenance.html>
<https://jp.mathworks.com/discovery/anomaly-detection.html>

「異常検知」で検索



異常検知

サイト内検索



センサーデータ解析と機械
学習 ~ 振動データからの
異常検出 ~



【補足】機械学習アルゴリズムの特徴について知るには？

eBook



[MATLABによる機械学習](#)

基礎から高度な手法やアルゴリズムまで



1: 機械学習のご紹介

教師あり学習・教師なし学習、適切なアルゴリズムの選択、実際の事例など、機械学習の基礎を紹介します。

2: はじめての機械学習

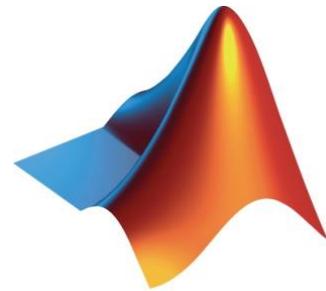
データへのアクセスと読み込み、データの前処理、特徴抽出モデルのトレーニングと調整について説明します。

3: 教師なし学習の適用

クラスタリングについて説明します。モデルのパフォーマンスを向上させるための一般的な次元削減の手法について紹介します。

4: 教師あり学習の応用

分類と回帰について説明し、特徴選択や特徴変換、ハイパーパラメータのチューニングといった、モデルを改善する手法を紹介します。



MathWorks®

Accelerating the pace of engineering and science

© 2018 The MathWorks, Inc. MATLAB and Simulink are registered trademarks of The MathWorks, Inc. See www.mathworks.com/trademarks for a list of additional trademarks. Other product or brand names may be trademarks or registered trademarks of their respective holders.