

# Part 4: 機器の寿命を予測するモデル構築



# Predictive Maintenance Toolbox

## 予知保全アルゴリズム開発の効率UP


R2018a

### 予知保全向けの機能

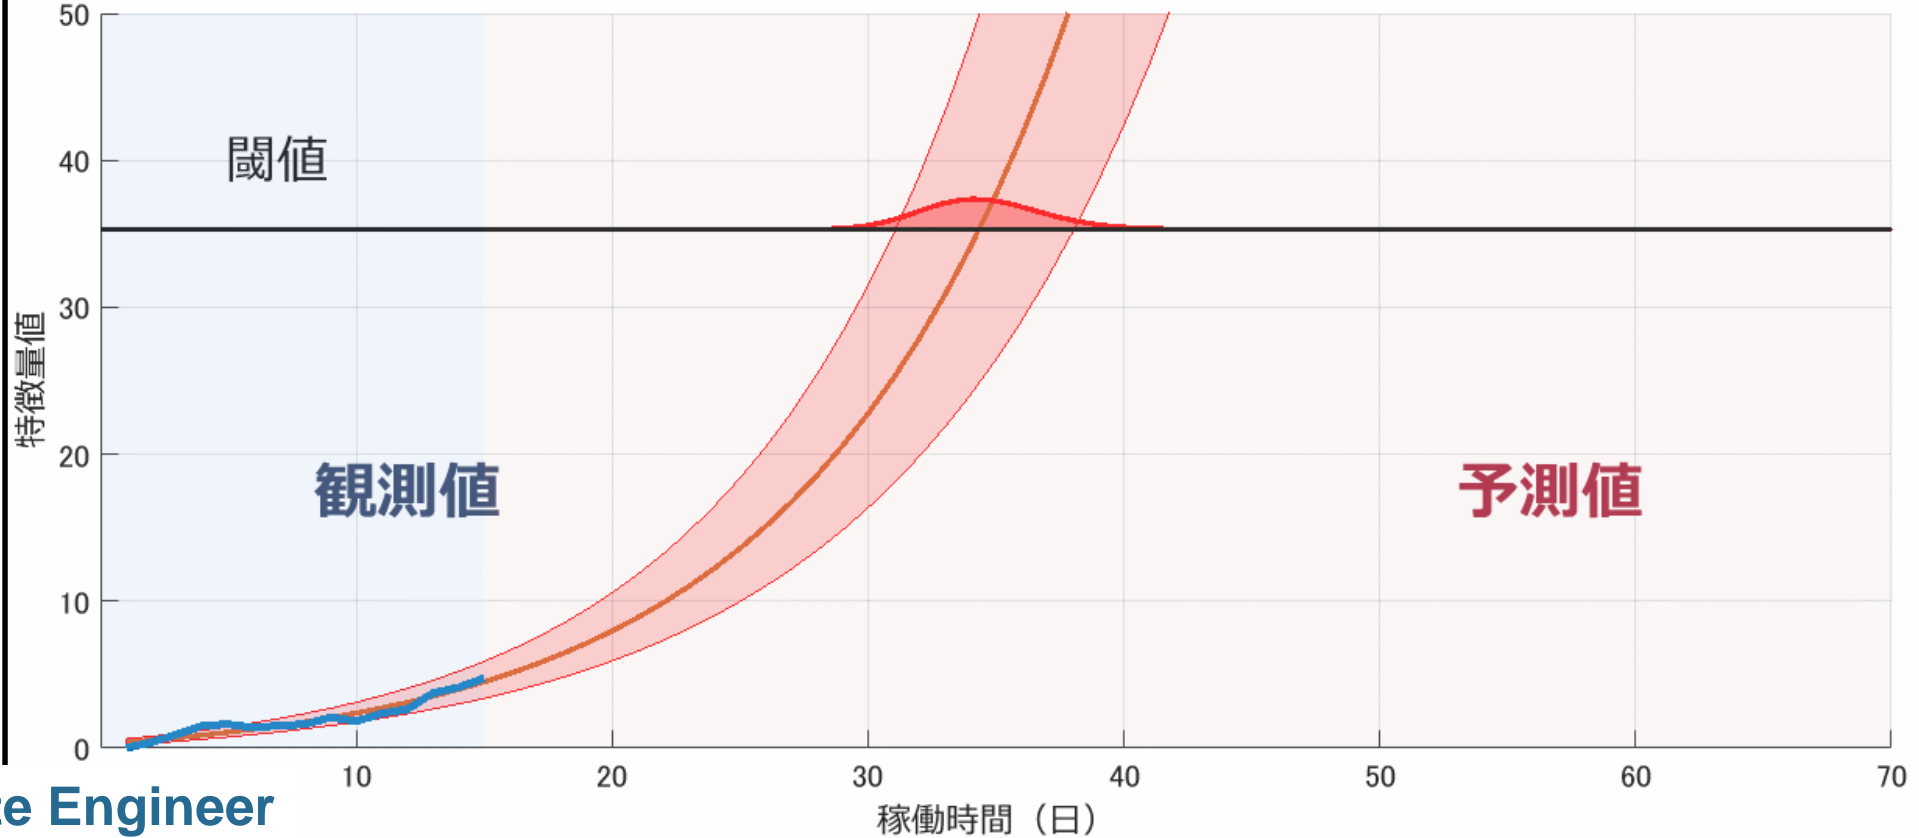
- 予測モデル作成向けのデータ管理機能
- 機器の残り寿命を予測するモデル
- 機器の状況を表す特徴量を抽出する機能
- Simulinkモデルを使った故障データ作成



# 故障予測の実施例



故障まで残り 459 時間  
(95%信頼区間 : 374~558 時間)



Site Engineer

# 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

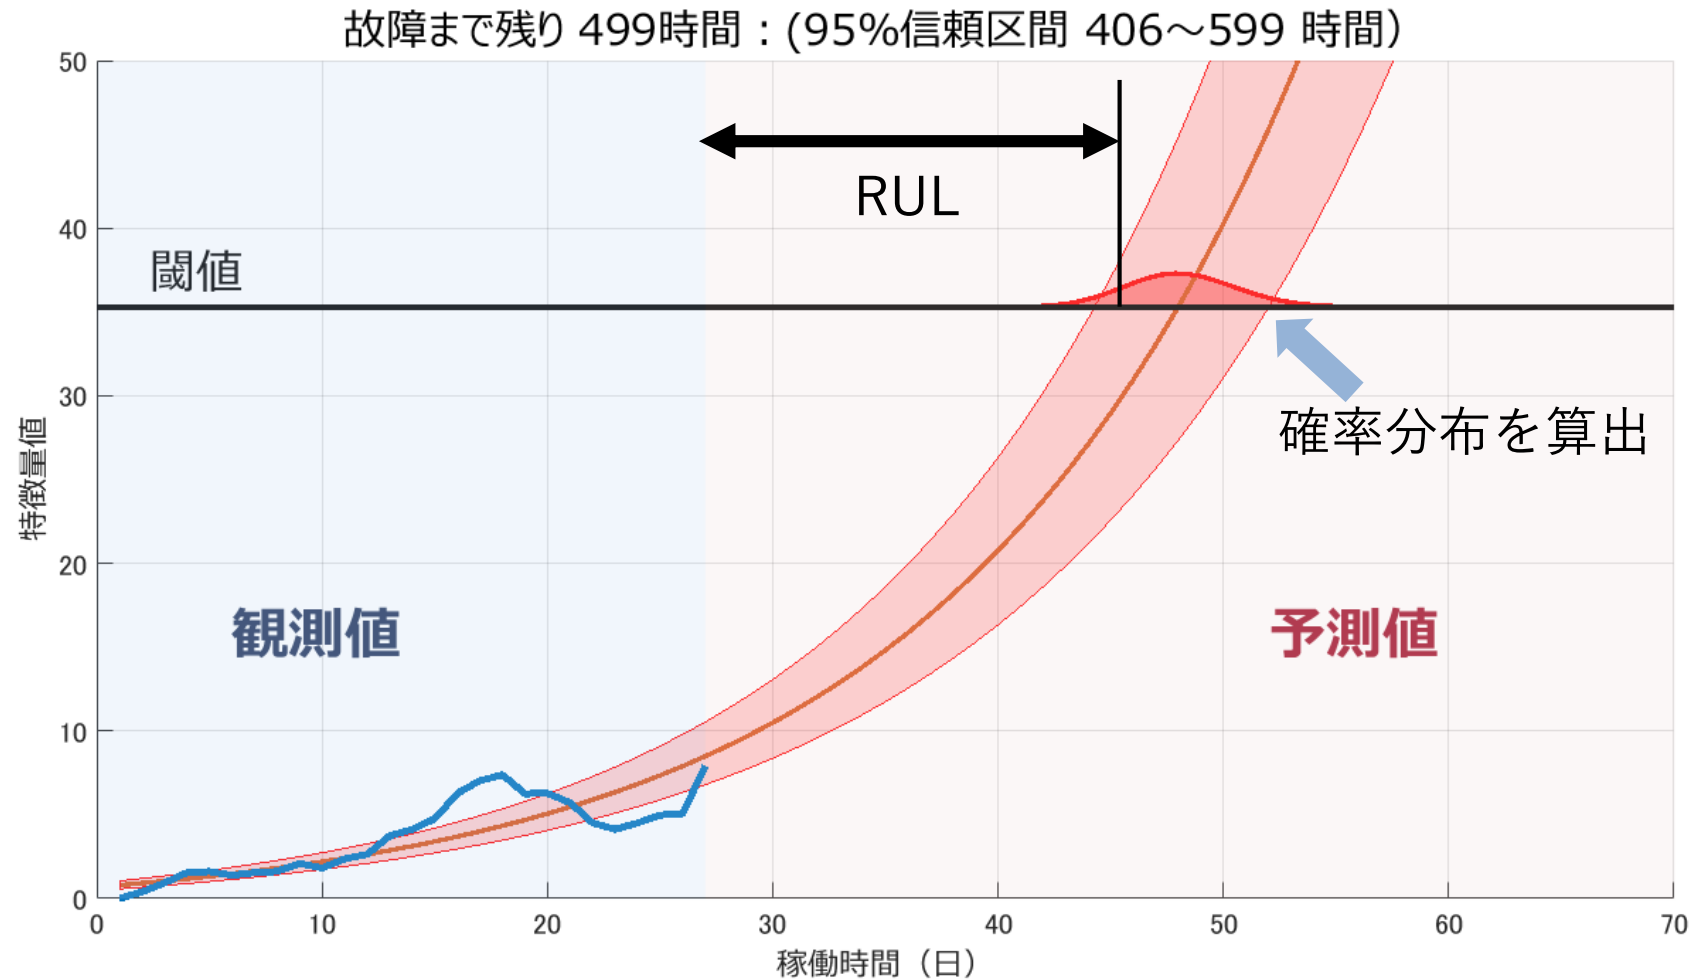


データ元 : <http://data-acoustics.com/measurements/bearing-faults/bearing-3/>


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.*

# Demo : 風力タービンの故障予測アルゴリズム開発



# 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

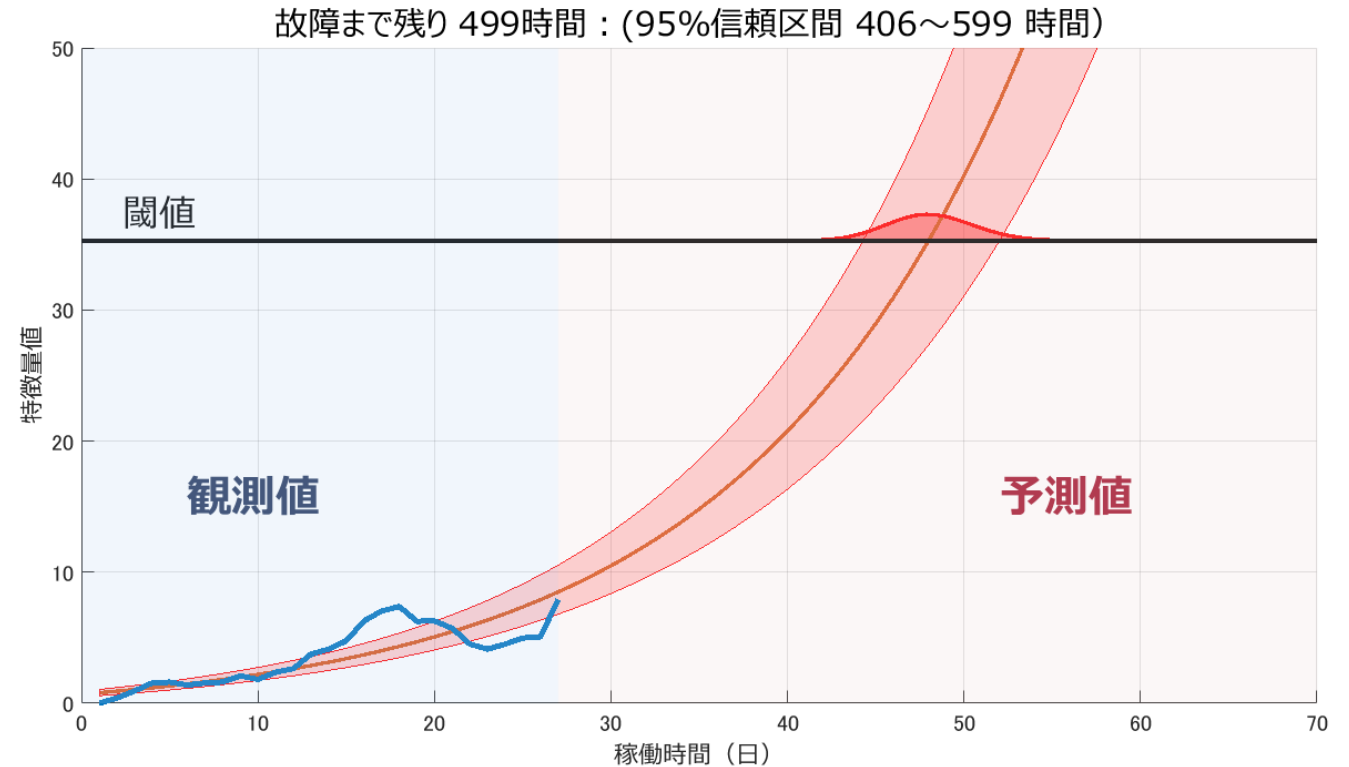


# Demo : 風力タービンの故障予測アルゴリズム開発

## Step 1: 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

## Step 1-1: 15種類の特徴量を算出

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

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

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

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

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

## Demo : 風力タービンの故障予測アルゴリズム開発

### Step 1-1: 15種類の特徴量を算出 (続き)

7. 波高率 : ピーク値/実効値 (Crest Factor)
8. 波形率 : 実効値/平均値 (Shape Factor)
9. インパルス係数 (Impulse Factor)
10. マージン係数 (Margin Factor)
11. 二乗和 (Energy)
12. スペクトル尖度の平均値 (Skmean)
13. スペクトル尖度の標準偏差 (SKStd)
14. スペクトル尖度の歪度 (SKSkewness)
15. スペクトル尖度の尖度 (SKKurtosis)

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

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

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

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

# Demo : 風力タービンの故障予測アルゴリズム開発

## Step 1-1: 15種類の特徴量を算出 (MATLABコード一部)

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

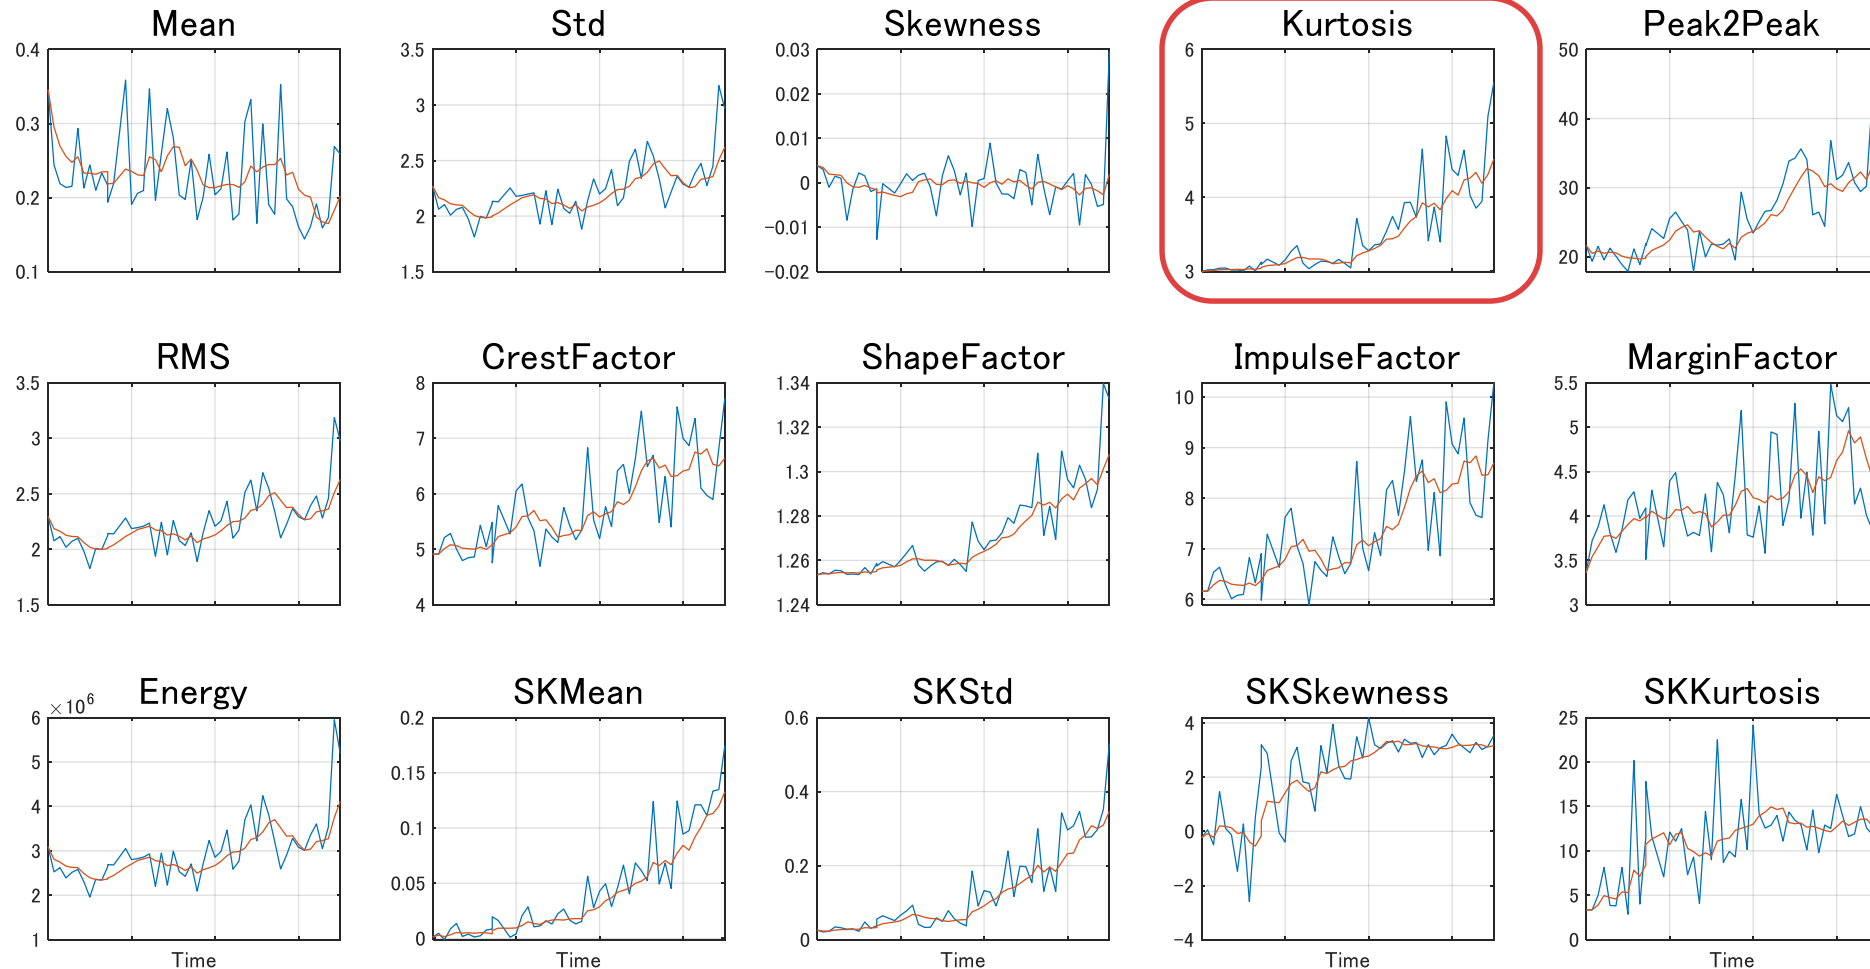
    % 時間領域における各種特徴量(一部)
    features.Mean = mean(v);
    features.Std = std(v);
    features.Skewness = skewness(v);
    features.Kurtosis = kurtosis(v);

    % 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
```

# Demo : 風力タービンの故障予測アルゴリズム開発

## Step 1-1: 15種類の特徴量を算出 (50日間の推移)



# Demo : 風力タービンの故障予測アルゴリズム開発

## Step 1: 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

3: 特徴量の選択・生成

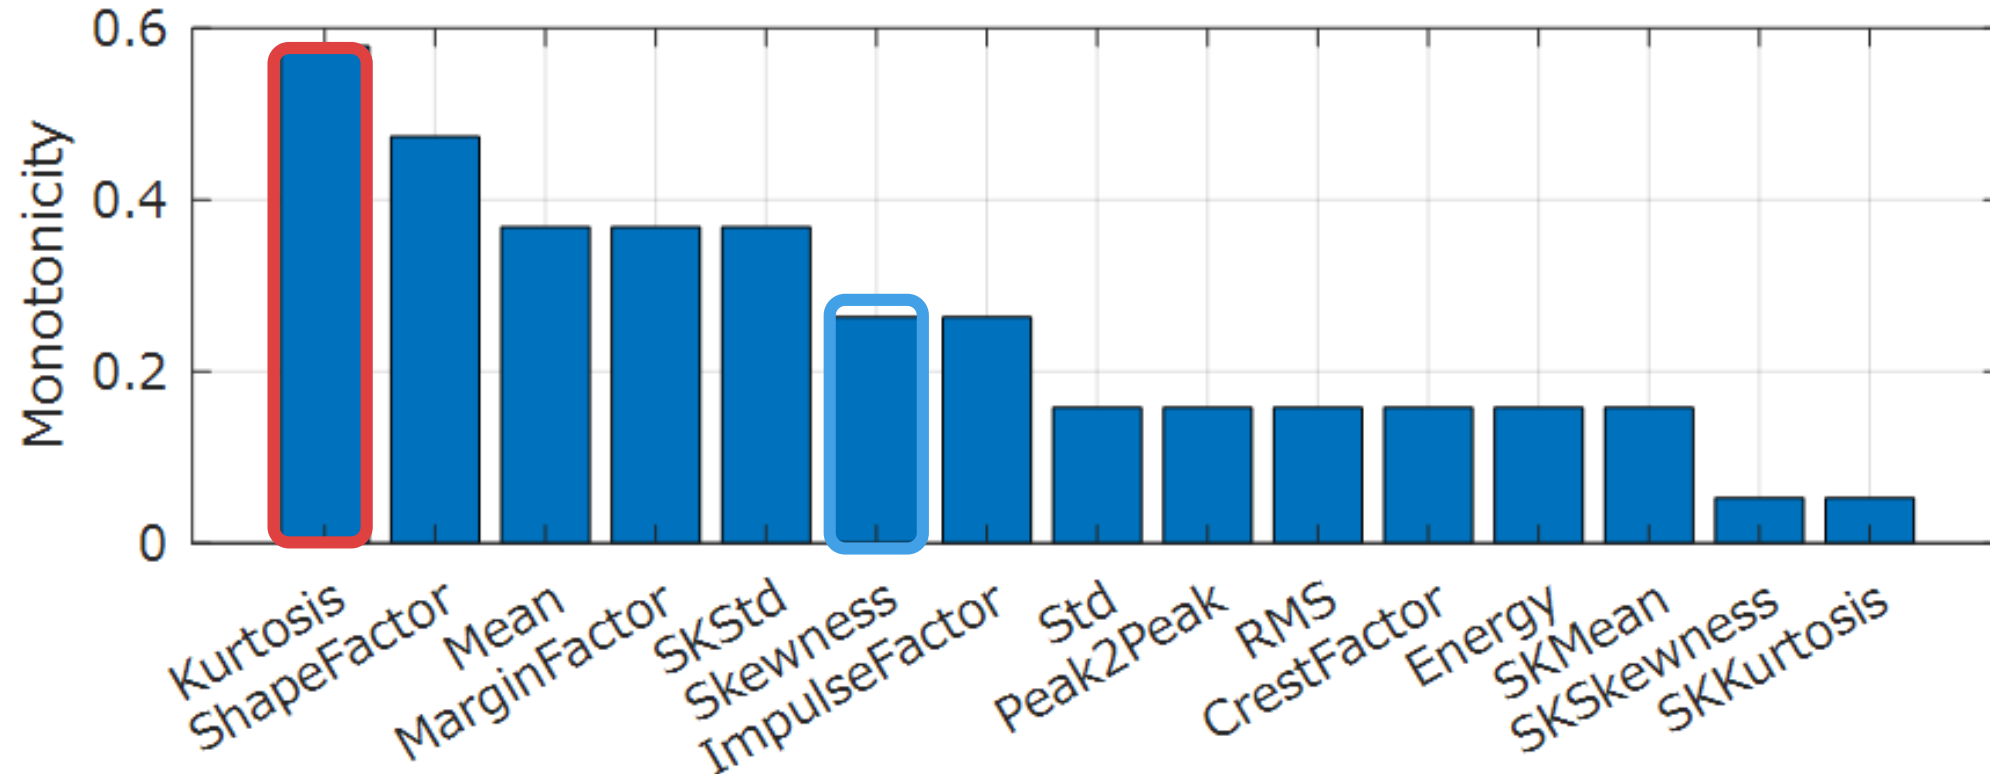
Coble, Jamie Baalis. "Merging data sources to predict remaining useful life—an automated method to identify prognostic parameters." *PhD diss., University of Tennessee, 2010.*

# Demo : 風力タービンの故障予測アルゴリズム開発

## Step 1-2: 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

## Step 1-3: 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

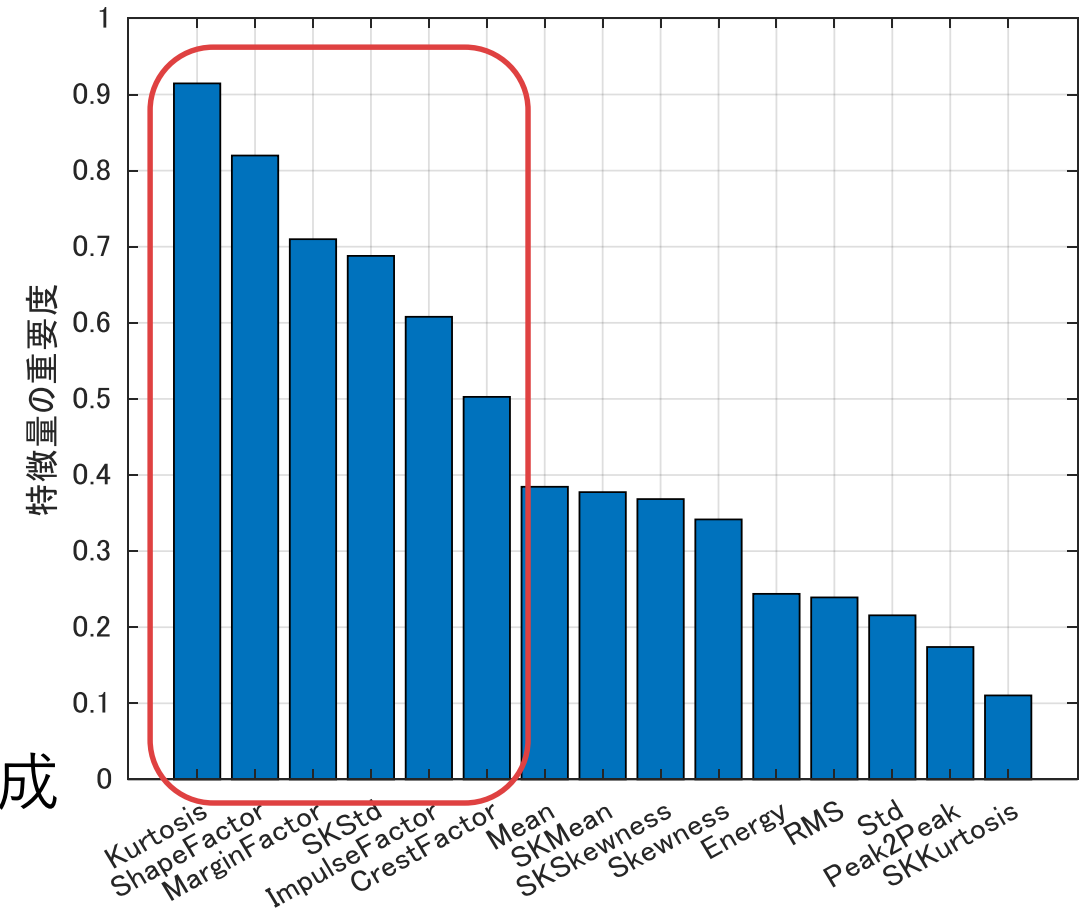
1: 15種類の特徴量を算出

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



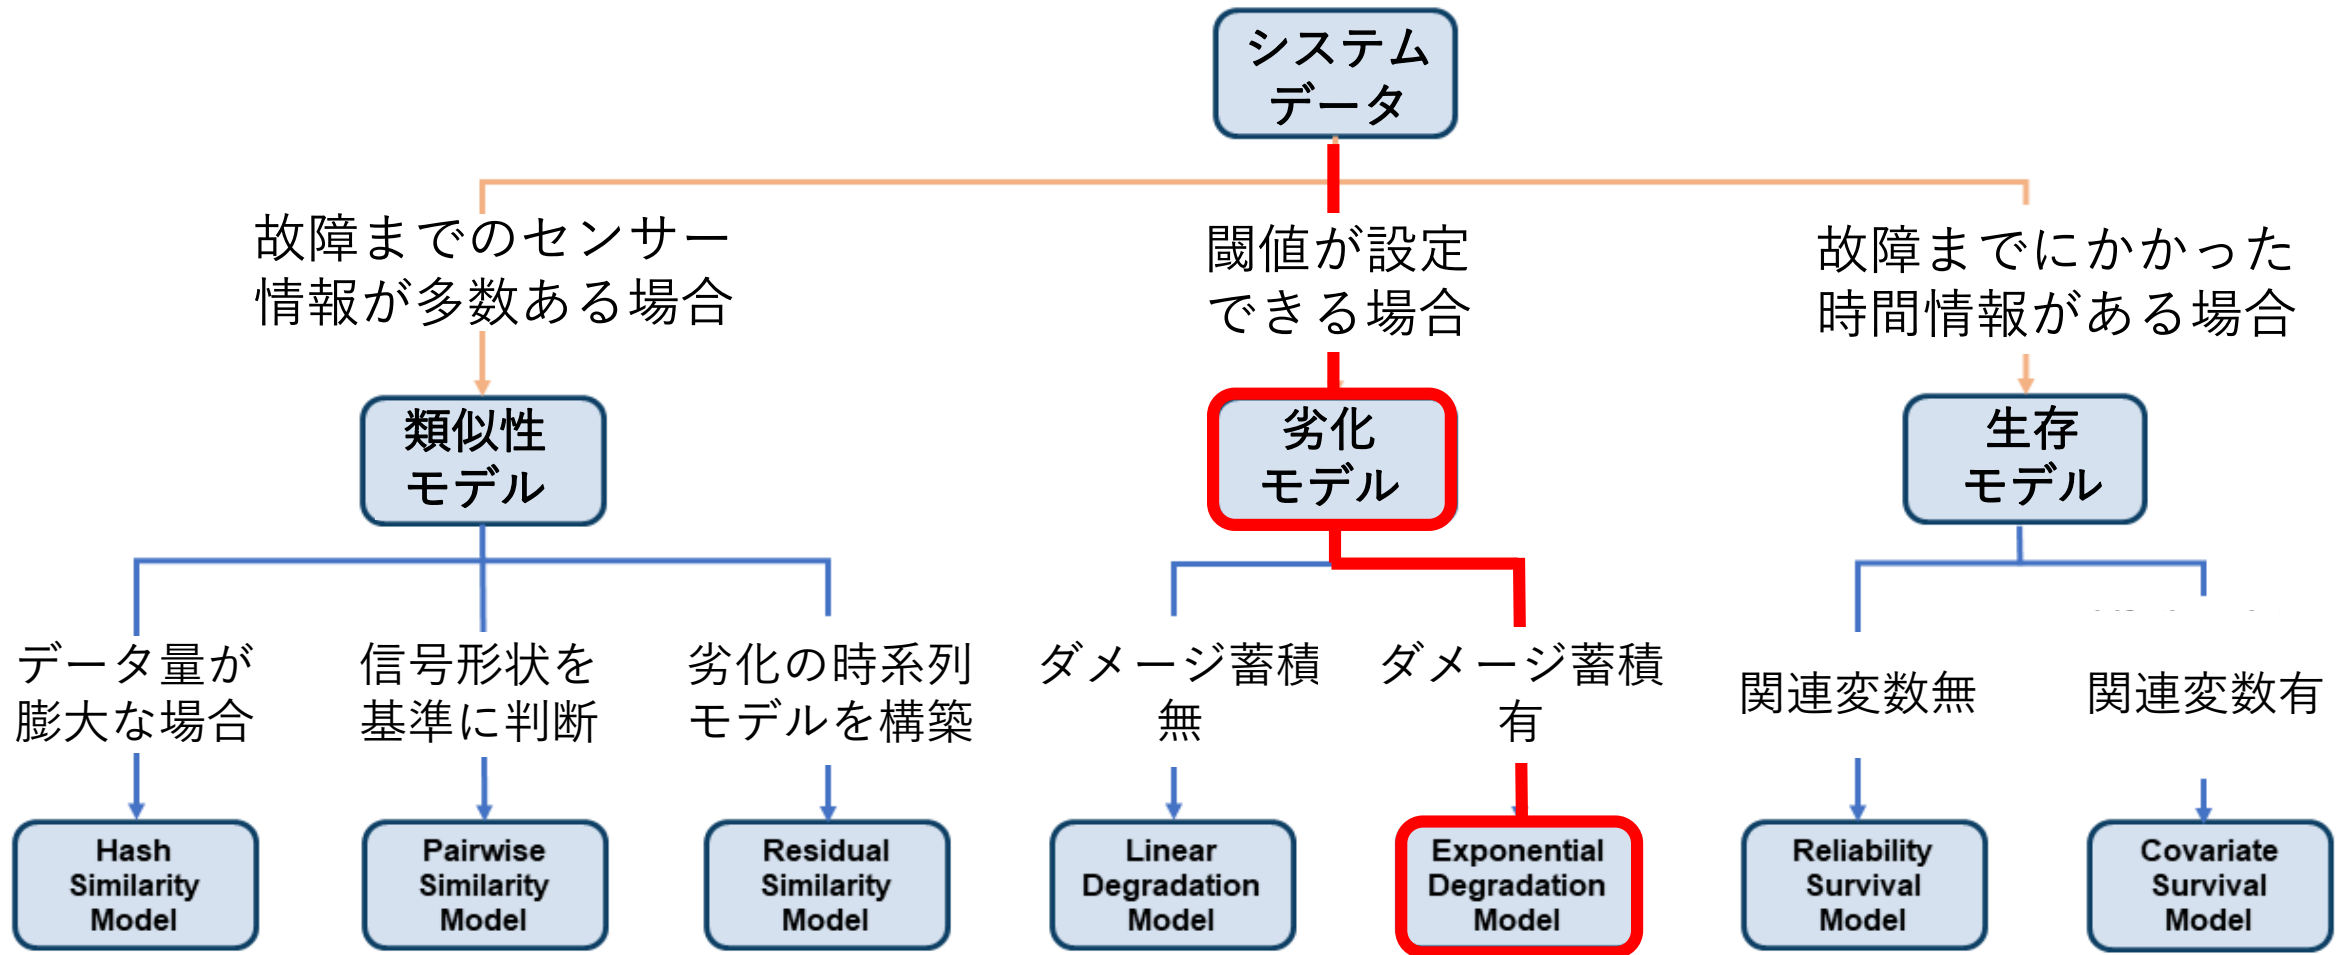
# Demo : 風力タービンの故障予測アルゴリズム開発





# 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)])
```

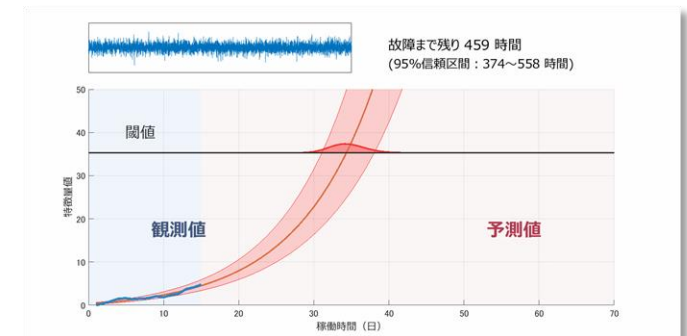
% RULの予測

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


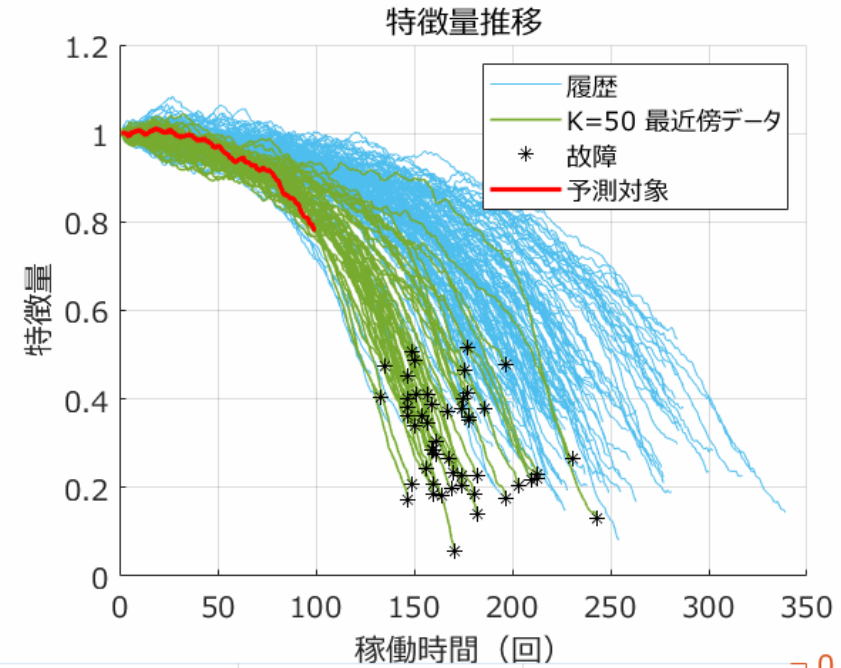

```
end
```

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】 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, Wahyu, et al. "An application of nonlinear feature extraction-A case study for low speed slewing bearing condition monitoring and prognosis." *Advanced Intelligent Mechatronics (AIM), 2013 IEEE/ASME International Conference on. IEEE, 2013.*

[2] Loughlin, P., F. Cakrak, and L. Cohen. "Conditional moments analysis of transients with application to helicopter fault data." *Mechanical Systems and Signal Processing 14.4 (2000): 511-522.*



# 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](http://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.