

予知保全のための信号処理 ～応用例～



アプリケーションエンジニアリング部
竹本佳充

応用例1: 信号処理を用いた例

ギア/ベアリングの異常検知


- 概要
- Case 1: 大歯車の歯の破損
- Case 2: 小歯車の偏芯
- Case 3: ベアリングのクラック

概要



小歯車、大歯車、かみ合い周波数からの寄与分を考慮した振動波形


- 小歯車：22.5Hz
- 大歯車：8.36Hz
- かみ合い周波数：292.5kHz



$$f_{\text{Gear}} = f_{\text{Pinion}} \times \frac{\text{Number of pinion teeth } (N_p)}{\text{Number of gear teeth } (N_g)}$$

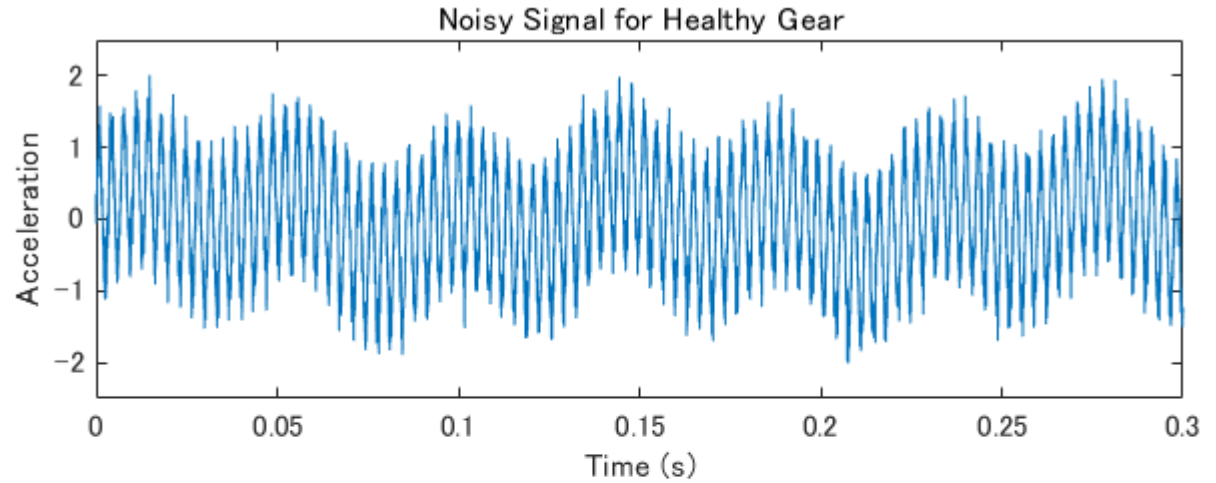
$$f_{\text{Mesh}} = f_{\text{Pinion}} \times N_p = f_{\text{Gear}} \times N_g$$

Case 1: 歯の破損による高周波衝撃

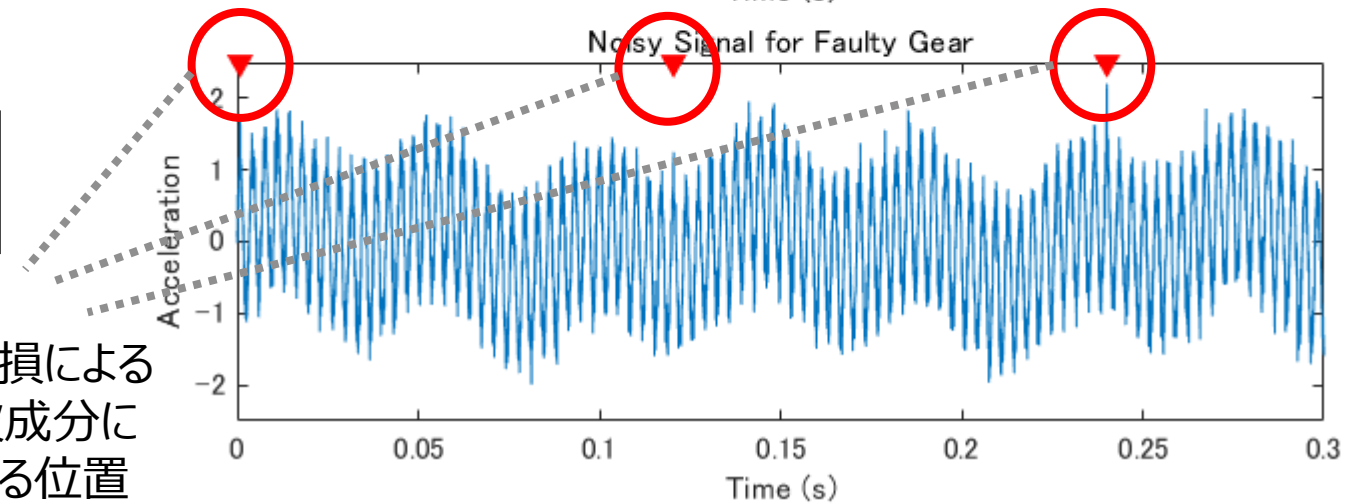


1/fMesh (0.25 ミリ秒) の 8% の時間で
2 kHz の振動信号が発生すると仮定

歯の破損による
高周波成分に
相当する位置



破損なし



破損あり


時間軸で視覚的に故障成分を見つけるのは困難

Case 1: 従来の周波数解析

破損に起因する周波数成分

$$f_{\text{sideband,Pinion}} = f_{\text{Mesh}} \pm m \times f_{\text{Pinion}} \quad \forall m \in \{1, 2, 3, \dots\}$$


$$f_{\text{sideband,Gear}} = f_{\text{Mesh}} \pm m \times f_{\text{Gear}} \quad \forall m \in \{1, 2, 3, \dots\}$$




R2017b

```
[Spect, f] = pspectrum(...
[vFaultNoisy' vNoFaultNoisy'], ...
Fs, 'FrequencyResolution', 0.2, ...
'FrequencyLimits', [0 500]);
```

周波数軸でも、
雑音に埋もれて観測は困難



拡大



Case 1: 時間同期平均 (TSA)

R2017b

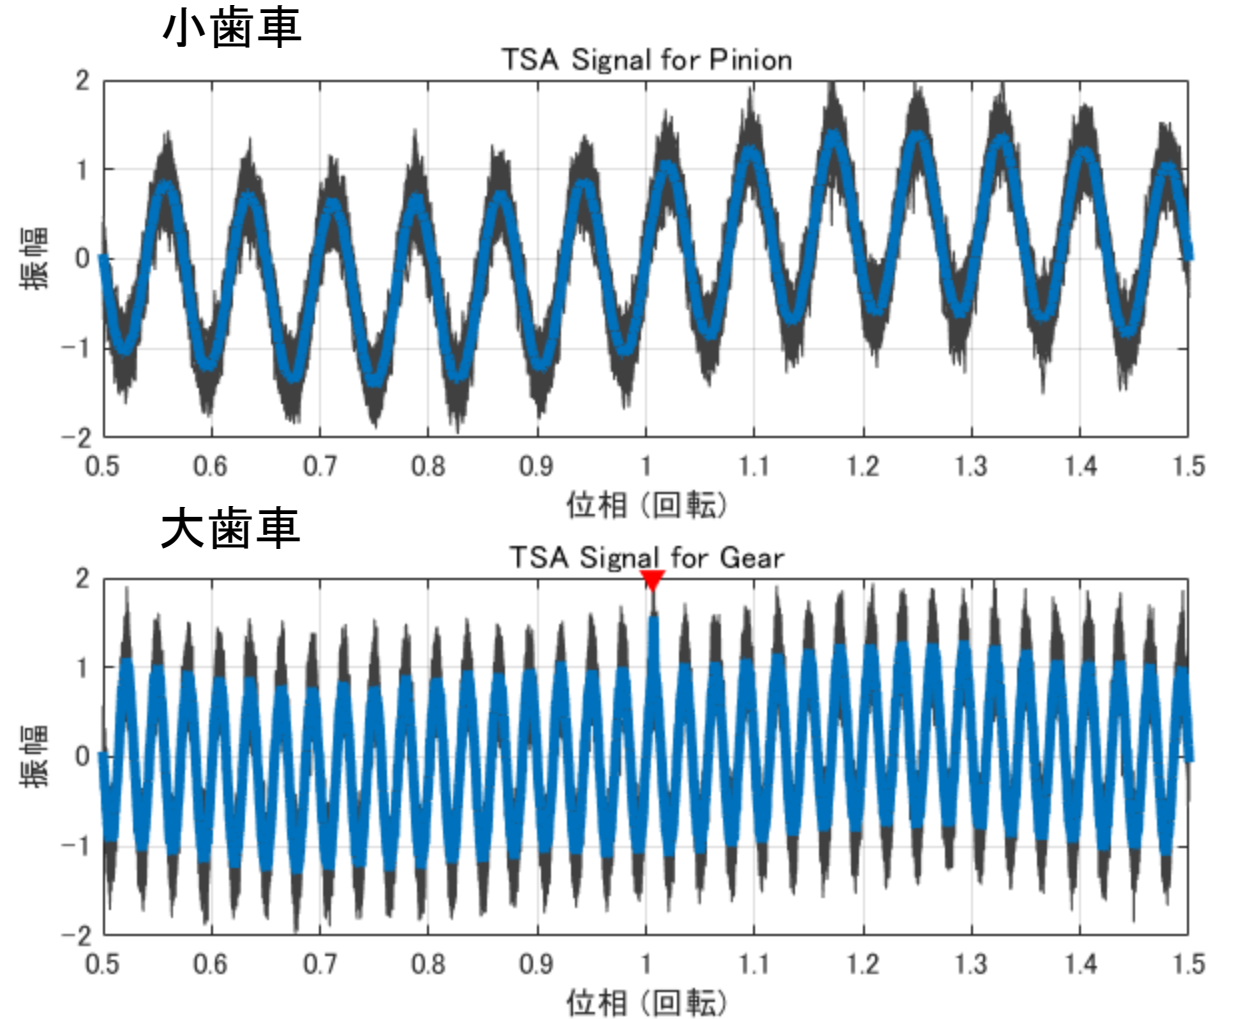
% 小歯車10回転分で同期させて平均化

```
tsa(vFaultNoisy, fs, tPulseIn, ...  
'NumRotations', 10)
```

% 大歯車10回転分で同期させて平均化

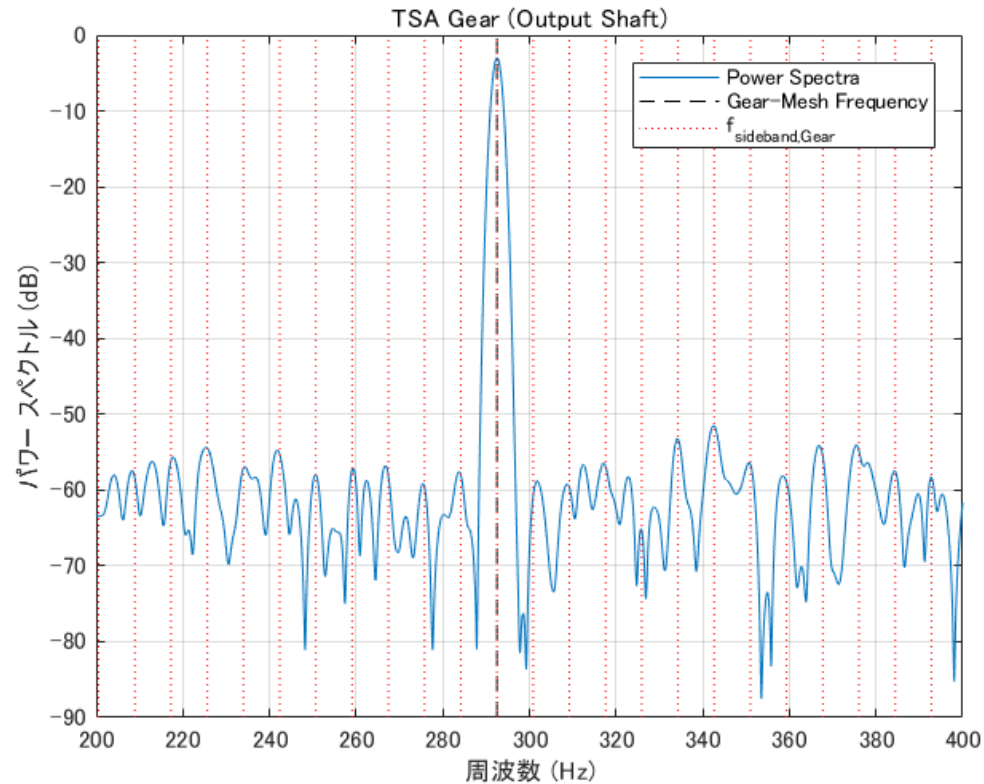
```
tsa(vFaultNoisy, fs, tPulseOut, ...  
'NumRotations', 10)
```

ランダム成分は平均化されて相殺
→ランダムでない成分が浮き彫り
→大歯車については、
衝撃による成分が読み取れる



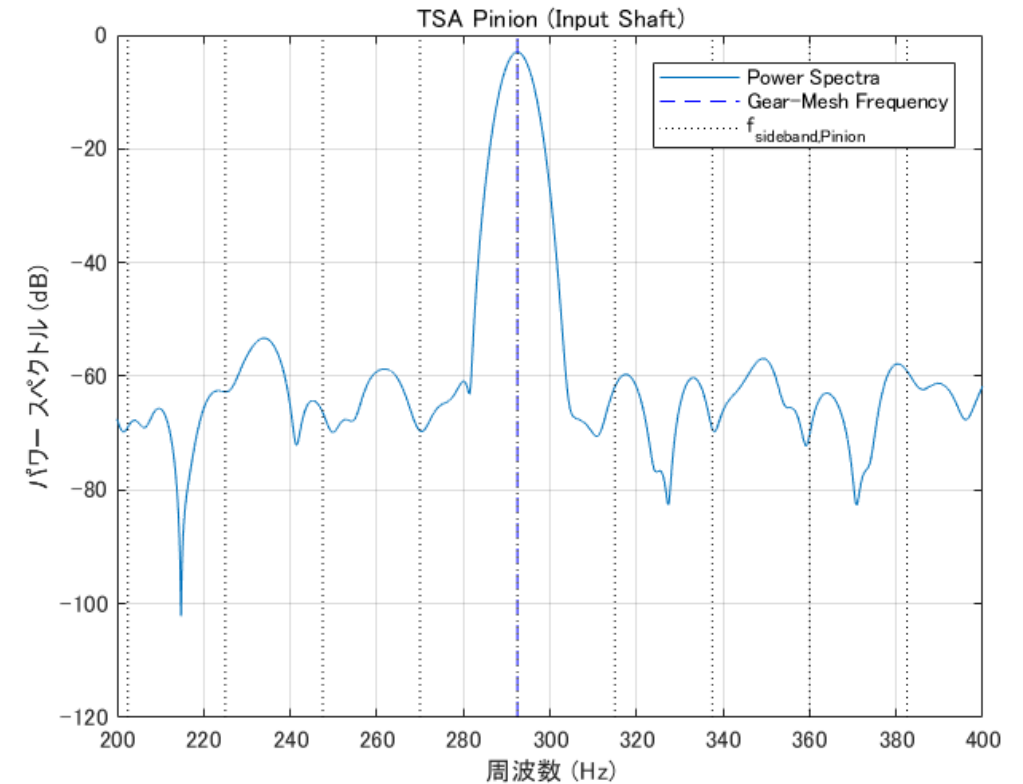
Case 1: 時間同期平均化した信号のスペクトル

大歯車




グリッド上にピーク有り
→故障の可能性大

小歯車



グリッド上にピーク無し
→故障の可能性は低い


Case 2: 小歯車の偏芯/ミスアライメント



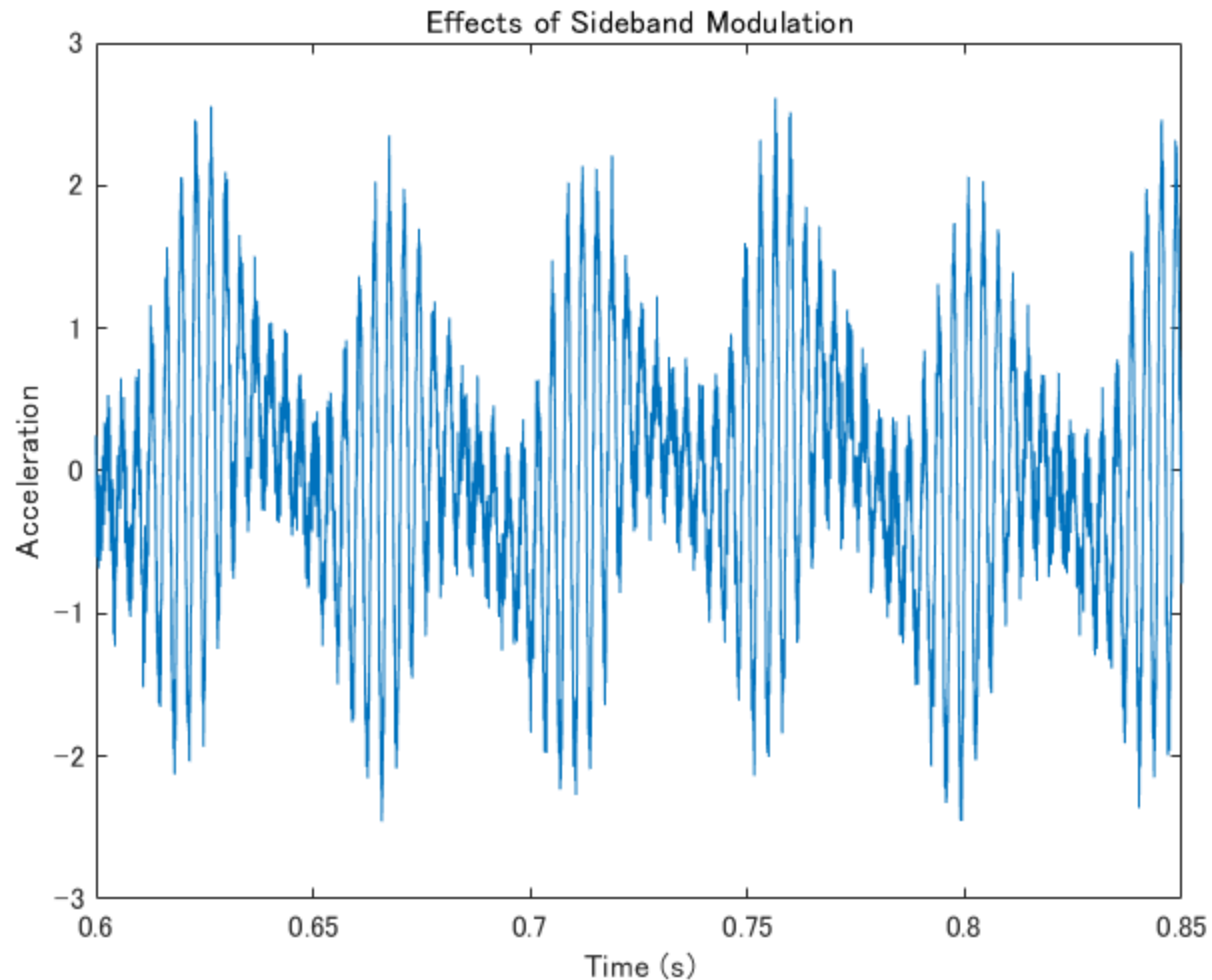
かみ合い周波数の整数倍付近で
狭帯域に分布する側波帯となる
→ここでは3つの側波帯を想定

```
SideBands = -3:3;
SideBandAmp = [0.02 0.1 0.4 0 0.4 0.1 0.02]; % Sideband amplitudes
SideBandFreq = fMesh + SideBands*fPin; % Sideband frequencies
vSideBands = SideBandAmp*sin(2*pi*SideBandFreq'.*t);
```

```
vPinFaultNoisy = vFaultNoisy + vSideBands;
```



Case 2: 偏芯のある小歯車信号の模擬



```
taPin = tsa(vPinFaultNoisy,fs,...  
tPulseIn,'NumRotations',10);
```

```
taGear = tsa(vFaultNoisy,fs, ...  
tPulseOut,'NumRotations',10);
```

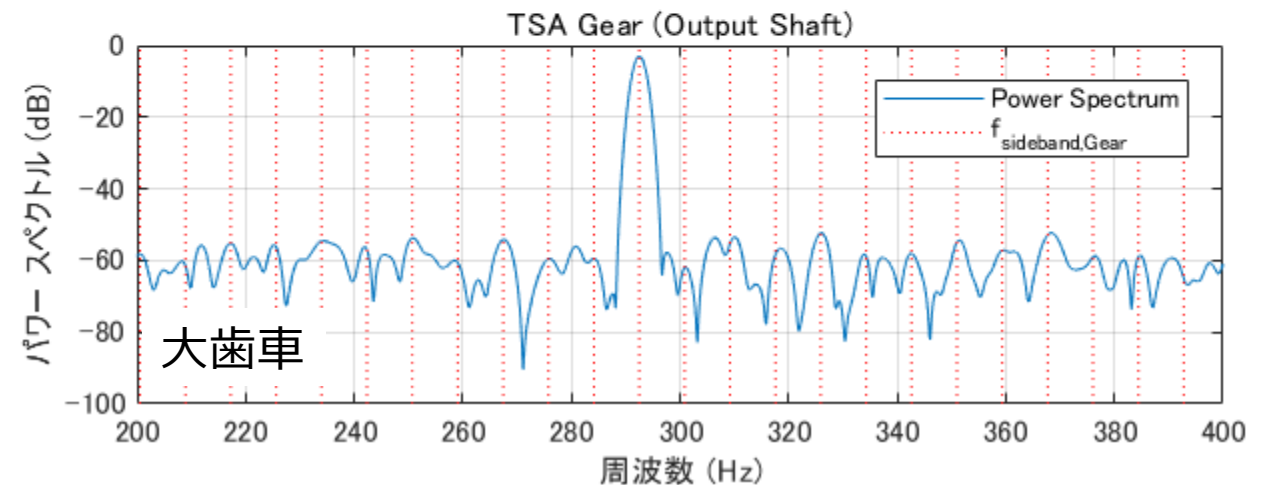
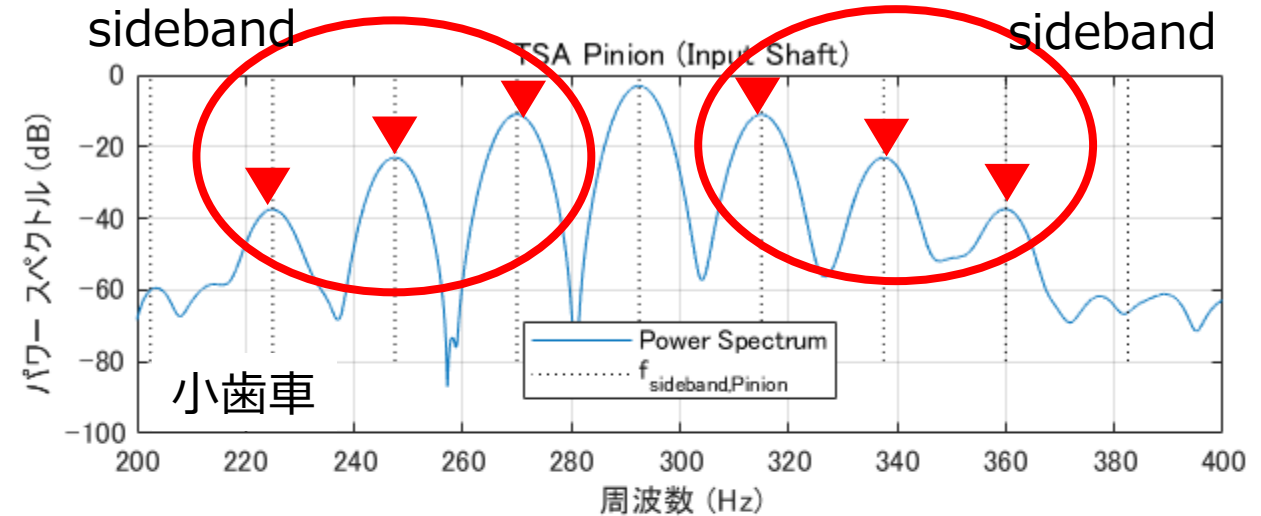
スペクトル計算の前処理として
時間同期平均を適用

Case 2: 偏芯のある小歯車信号のスペクトル

TSAをとった後の、
小歯車、大歯車のスペクトル

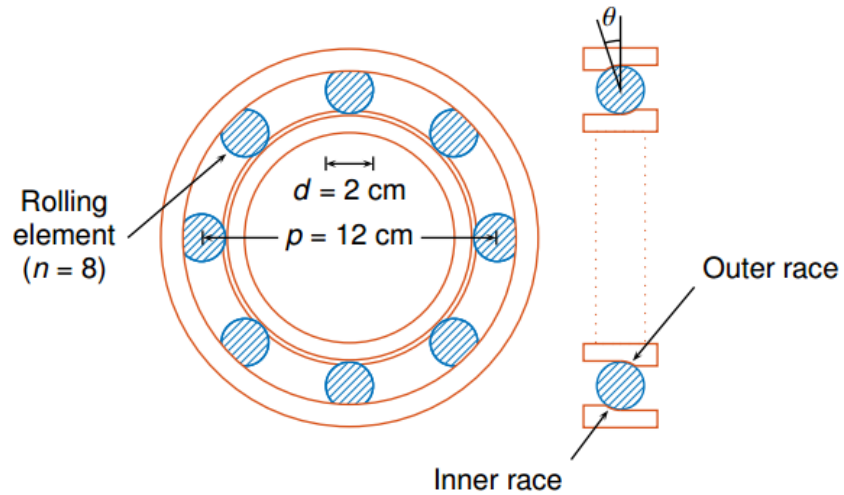

```
pspectrum(taPin, fs, ...
'FrequencyResolution', 5.8, ...
'FrequencyLimits', [200 400])
```

```
pspectrum(taGear, fs, ...
'FrequencyResolution', 2.2, ...
'FrequencyLimits', [200 400])
```

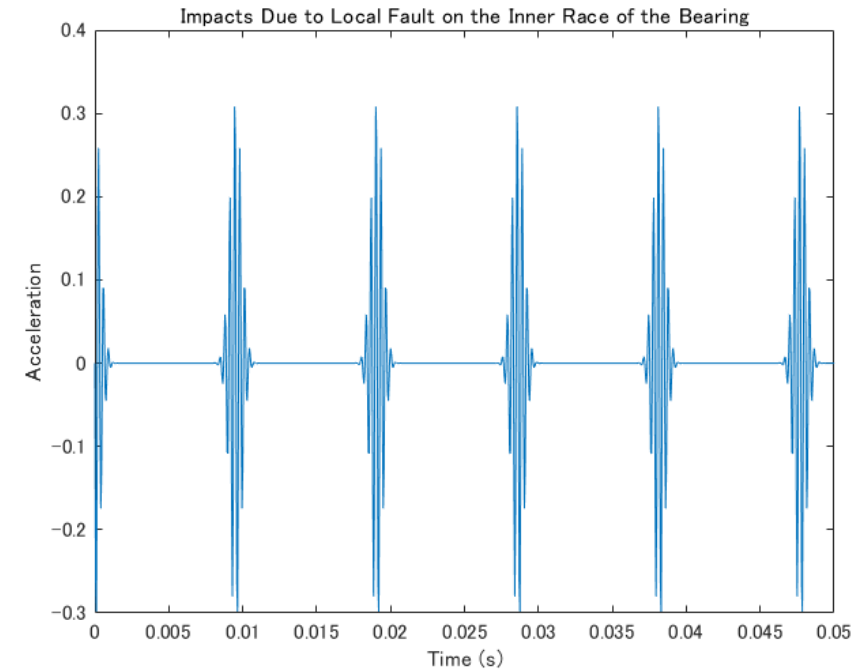


小歯車にサイドバンド有り
→小歯車に異常有り

Case 3: ベアリングの内輪のクラック



内輪のクラックに起因する衝撃信号

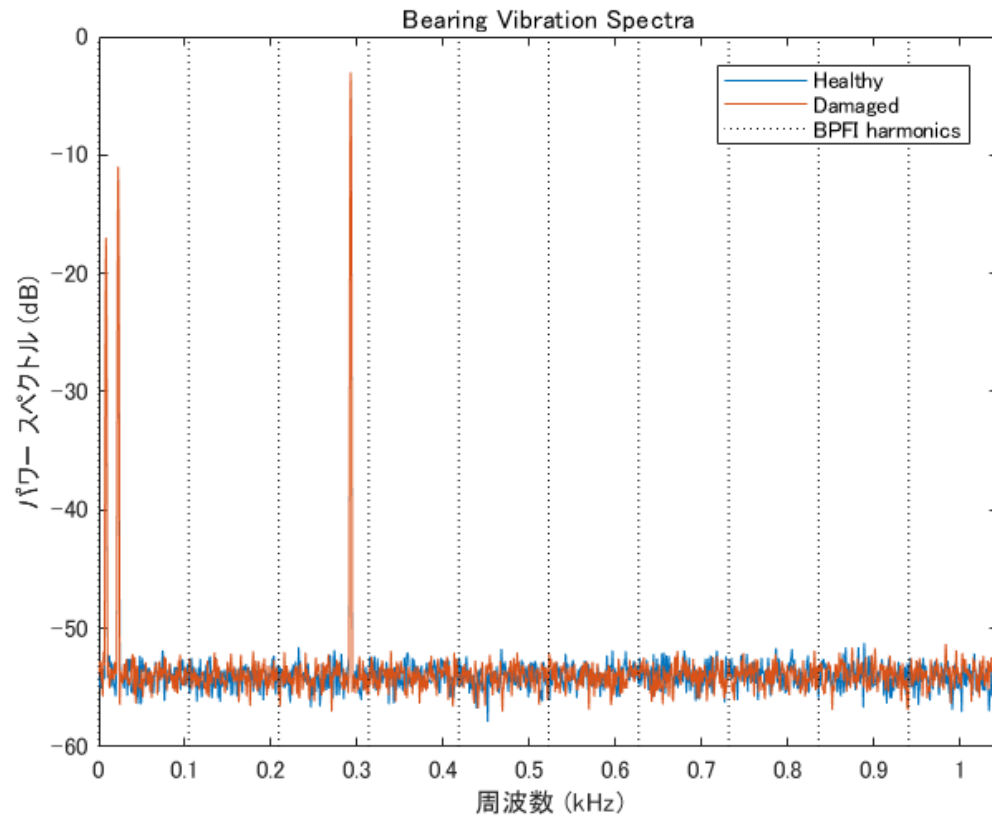


$$f_{\text{BPFI}} = \frac{n \times f_{\text{Pin}}}{2} \left(1 + \frac{d}{p} \cos \theta \right)$$

BPFI: ball pass frequency-inner race

Case 3: 欠陥のあるベアリングのスペクトル

ベアリングの欠陥を加味した信号のスペクトル



正常な場合と異常な場合のスペクトルが
区別できていない (BPFが観測できない)

BPFIは無理数

シャフト回転数 (整数) とは同期しない

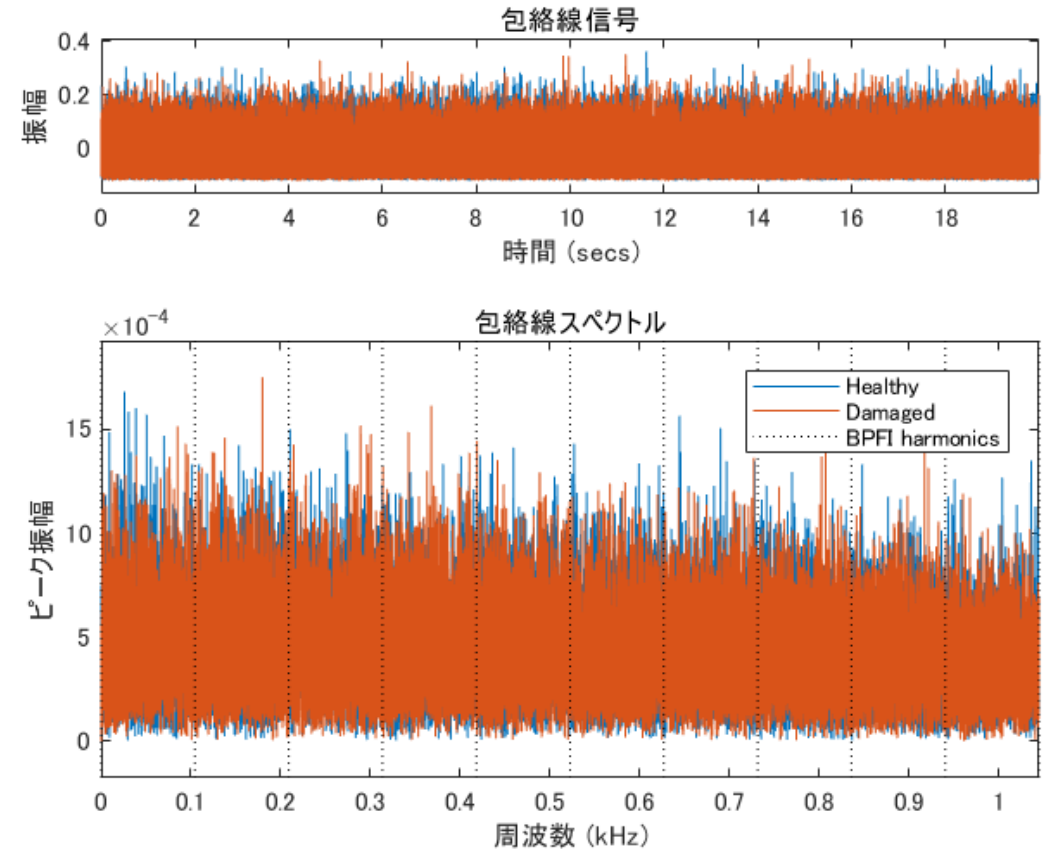
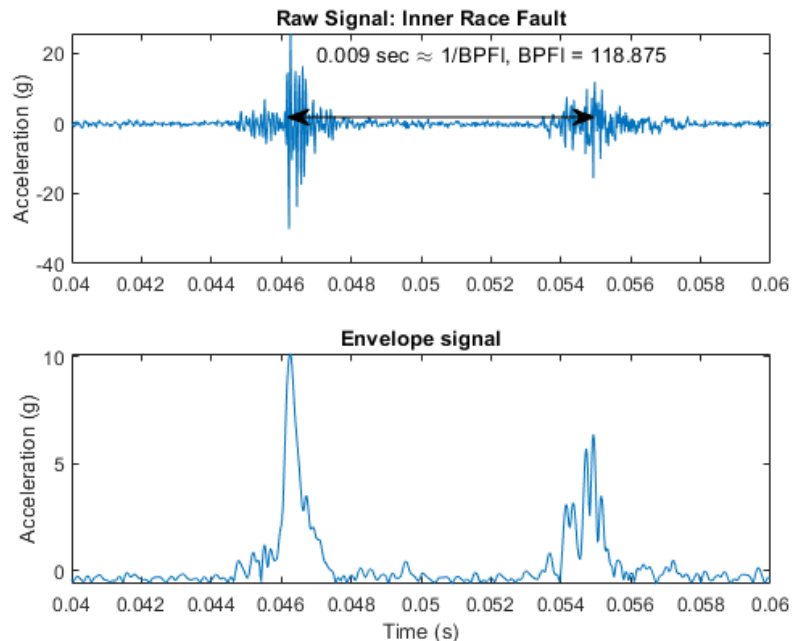
TSA (時間同期平均) は使えない

エンベロープスペクトルの適用

Case 3: エンベロープスペクトル

```
envspectrum([vNoBFaultNoisy' vBFaultNoisy'], fs)
```

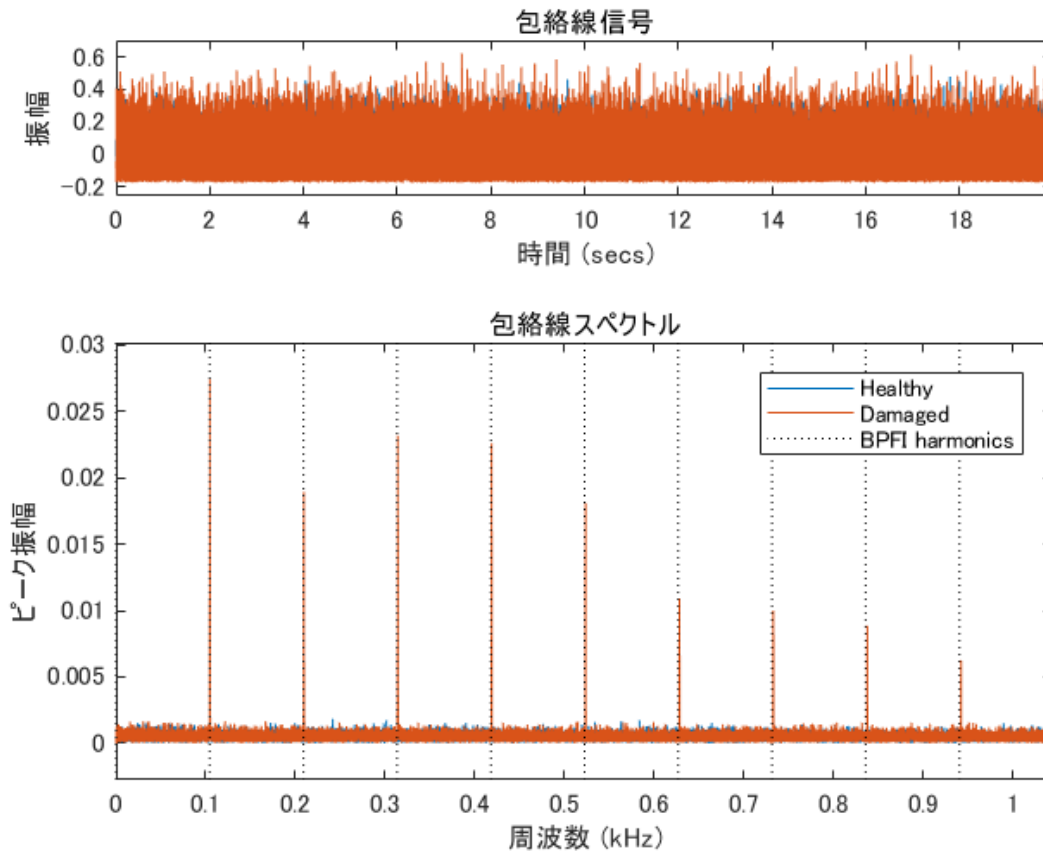
```
% エンベロープスペクトル
>> envspectrum(x, fs)
```



BPFIが雑音に埋もれている
→フィルタ処理を適用

Case 3: エンベロープスペクトル (フィルタ有り)


```
envspectrum([vNoBFaultNoisy' vBFaultNoisy'], fs, ...  
'Method', 'hilbert', 'FilterOrder', 200, ...  
'Band', [Fc-BW/2 Fc+BW/2])
```



BPFIの高調波成分が現れる
→内輪に異常あり

Case 3: エンベロープスペクトル(衝撃周波数近傍)

```
pspectrum([vBFaultNoisy' vNoBFaultNoisy'],fs,...  
'FrequencyResolution',1,...  
'FrequencyLimits',(bpfi*[-10 10]+fImpact))
```




BPFIは衝撃周波数で変調
→ 衝撃周波数(3kHz)近傍にも
BPFIと等間隔の成分を観測

応用例2: 信号処理 + ディープラーニングを用いた例 心拍データによる疾病の予知

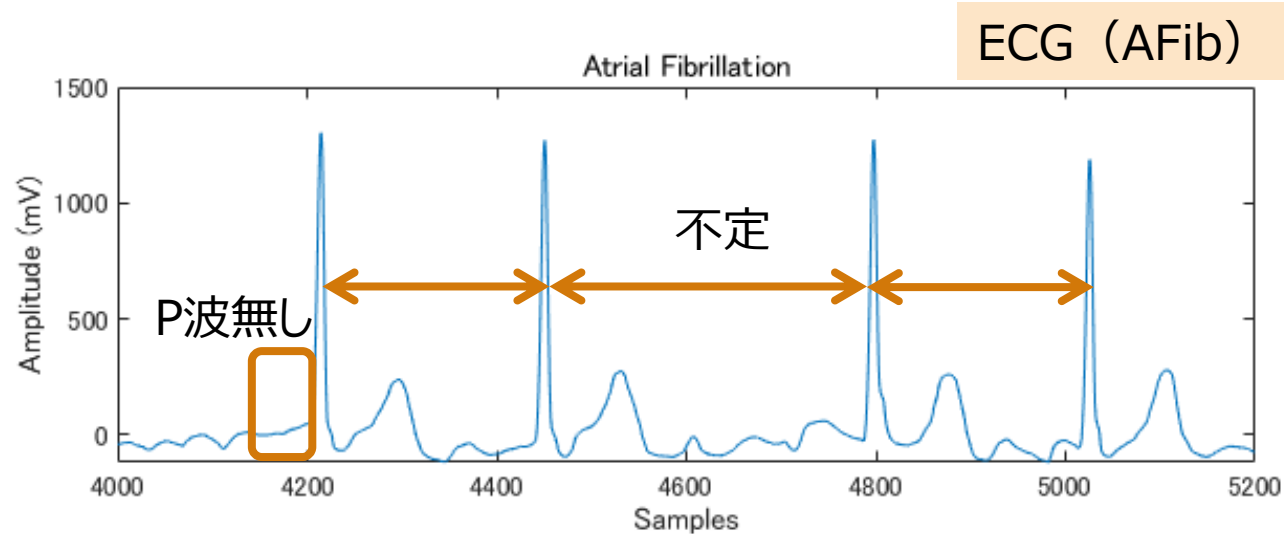
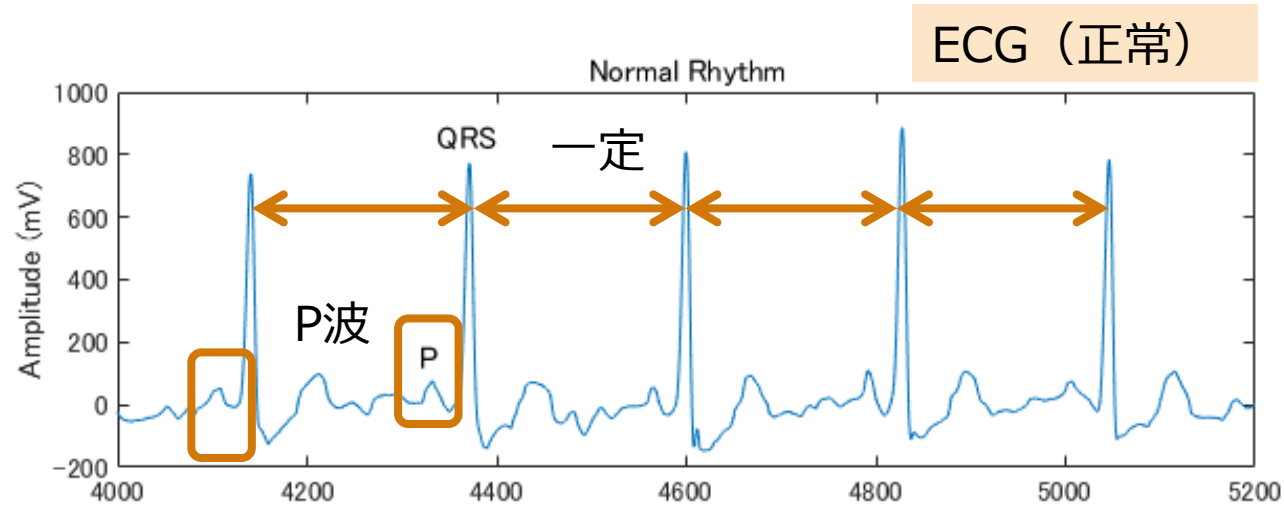
- Afibとは
- LSTMとは
- オーバーサンプリング
- 正規化
- 学習と評価

AFib (atrial fibrillation: 心房細動) とは？



- 不整脈の一種
- 通常は一定のリズムである
Atrium (心房) の活動が不規則
- 心房と心室間の調和が乱れる
- ECG (心電図) のQRS波の間隔が不定
- ECGのP波が観測されない

正常なECGとAFibのECG




課題：
深刻な疾病（心不全、脳梗塞等）の予兆
→自動判別する手法としてLSTMを適用

Recurrent Neural Network とは？

R2017b

1ステップ前の隠れ層の状態をフィードバックさせることで過去の情報を予測に活かせるようにしたネットワーク



エルマン型 RNN

長期間の依存関係を
モデル化するのが不得意

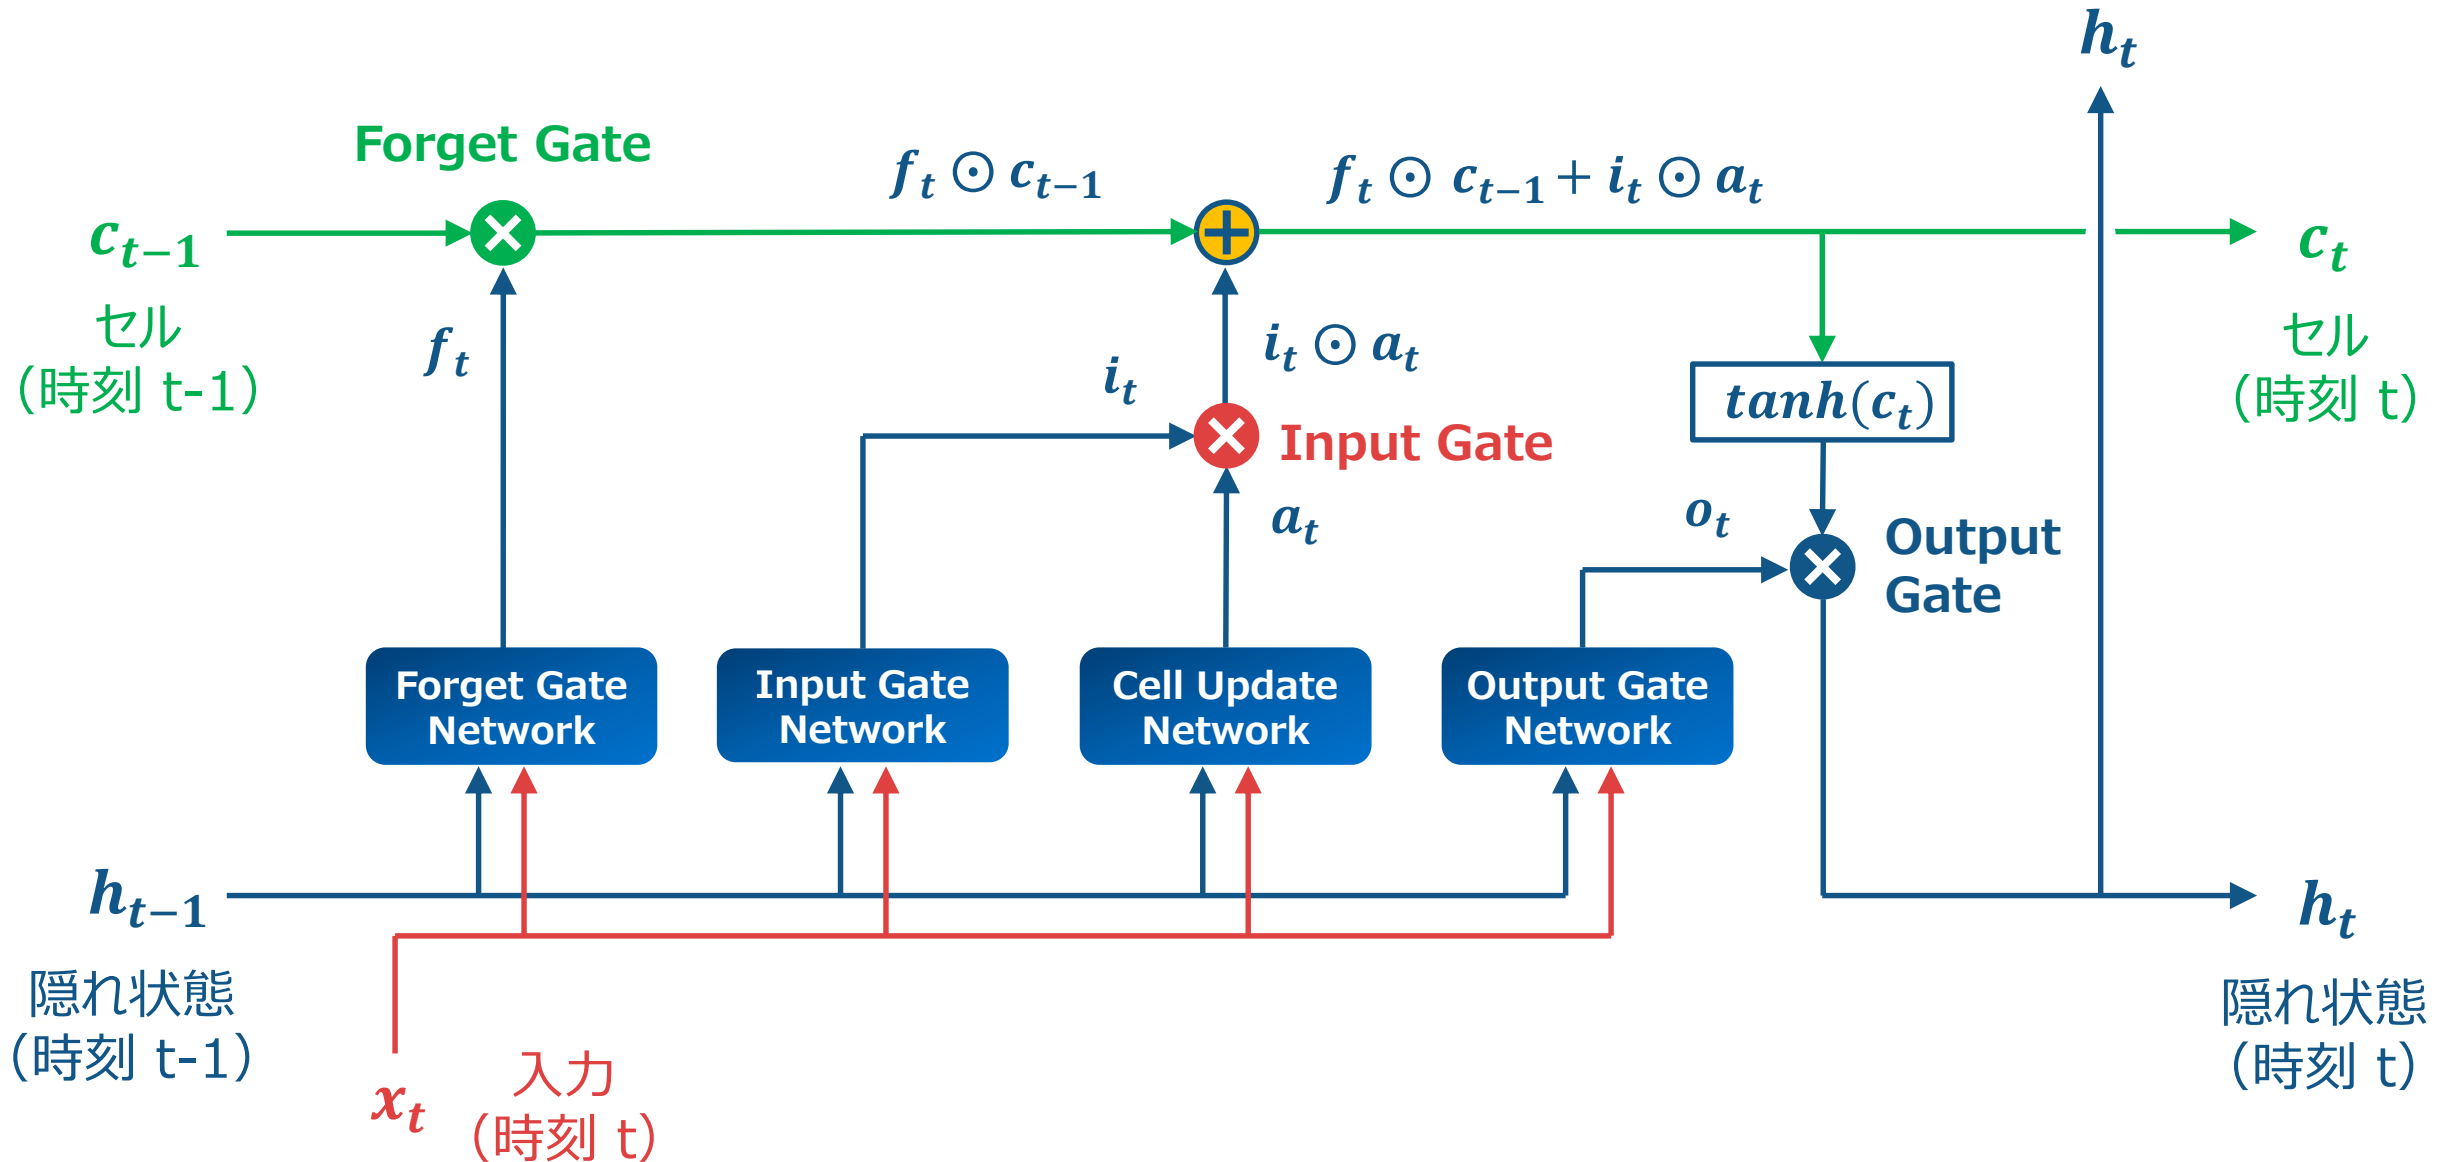
進化！



LSTM
Long Short-Term Memory

- 進化版RNN（ゲート付きRNN）
- メモリセルにより長期の情報を保持できる
- 時間的に離れた依存関係のモデル化も得意

LSTM (Long Short-Term Memory) とは？



データの偏りを回避：オーバーサンプリング

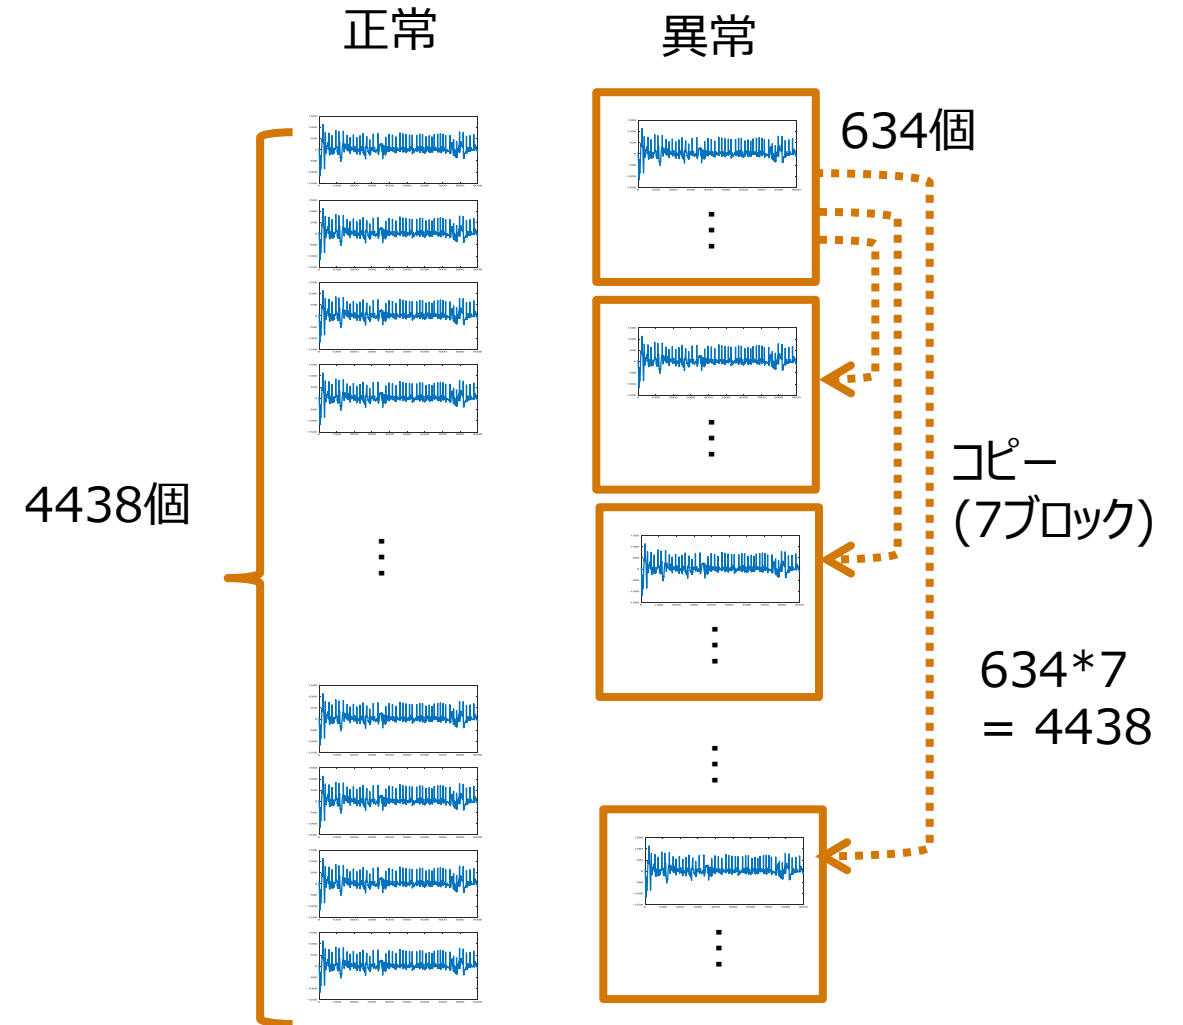
- 異常時のデータとは？
 - 機器の故障時（故障前）のセンサーデータ
 - 発症時（発症前）の患者のバイタルデータ
 - 災害時（災害前）の気象データ
- 一般に、“異常”なデータの確保は困難
➔ 偏りによる弊害



e.g) 本例題のケース

- 正常ECGデータ数：4438(87.5%)
- 異常ECGデータ数：634(12.5%)

全データを“正常”と判定しても、
見かけ上は高精度の分類となる



LSTMによる学習

■ 層設定

```
layers = [ sequenceInputLayer(1) % シーケンス入力
          bilstmLayer(100,'OutputMode','last') % 100の隠れ層を持つ双方向LSTM
          fullyConnectedLayer(2) % 全結合層
          softmaxLayer % ソフトマックス層
          classificationLayer % 分類出力]
```

■ 学習オプション

```
options = trainingOptions('adam', ...
    'MaxEpochs',10, ...
    'MiniBatchSize', 150, ...
    'InitialLearnRate', 0.01, ...
    'SequenceLength', 1000, ...
    'GradientThreshold', 1, ...
    'plots','training-progress', ...
    'Verbose',false);
```

■ 学習


```
net = trainNetwork(XTrain,YTrain,layers,options);
```

学習データ

ラベル


層設定

学習オプション




trainNetwork実行時の
学習過程

混合行列による評価



トレーニングデータ : 56.4%



テストデータ : 55.8%

課題 : 学習時間と学習精度の改善

特徴抽出による性能改善：時間-周波数分析

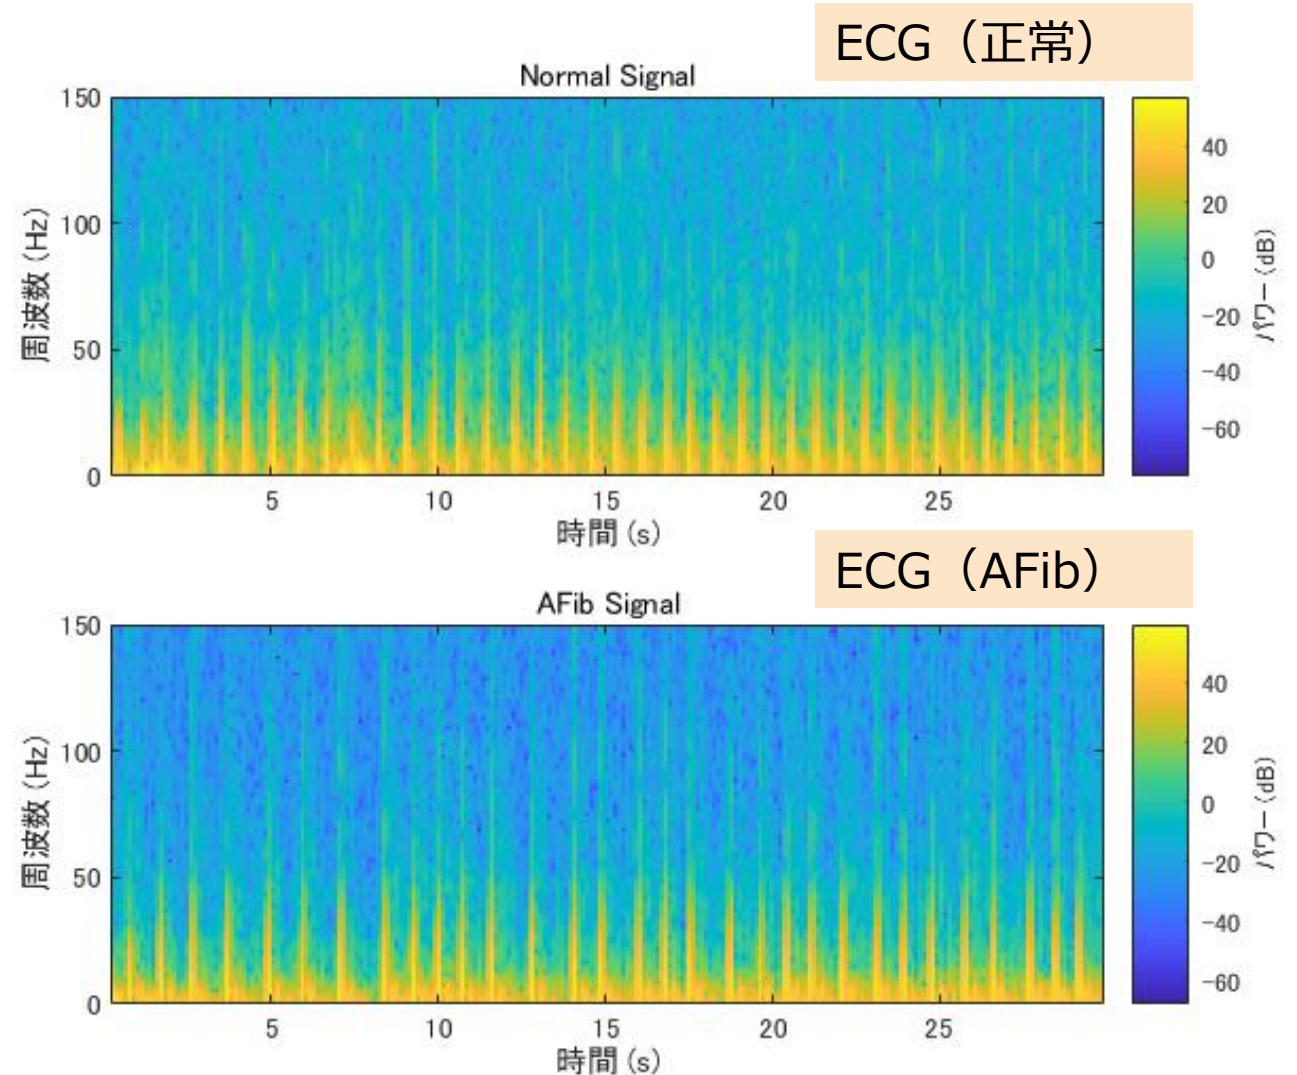
仮説：

- 正常なECGは規則的な信号
- Afibは不規則
- 時間-周波数分析が有効では？
- スペクトログラム





>> `pspectrum(signal,fs);`

課題：

LSTMで扱うために1次元化が必要



「瞬時周波数」と「スペクトルエントロピー」





■ 瞬時周波数 **R2018a**
 >>x = **instfreq**(signal,fs);

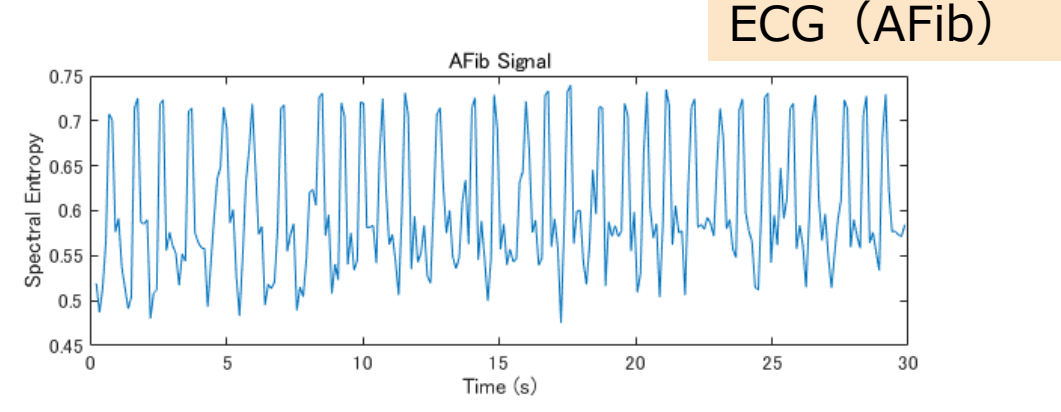
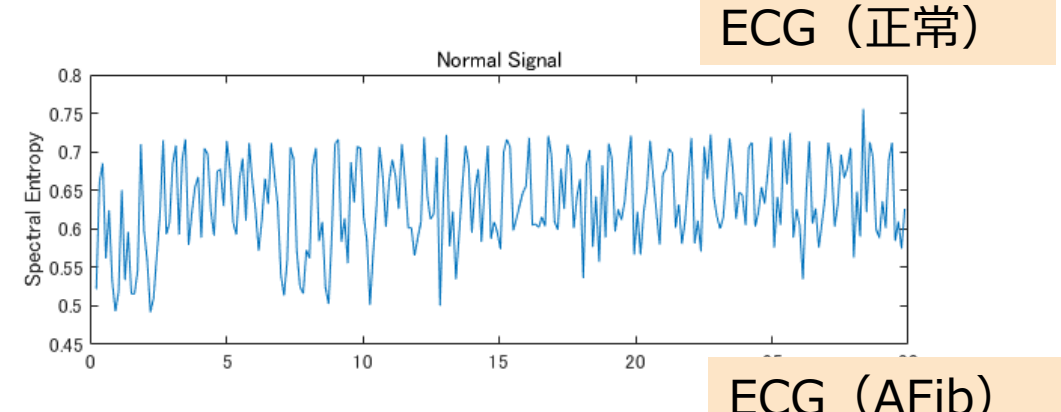
■ スペクトルエントロピー **R2018a**
 >>x = **pentropy**(signal,fs);

信号の特徴	スペクトルの特徴	瞬時周波数	スペクトルエントロピー
正弦波的	尖る (線スペクトル)	支配的な周波数成分に依存	小
ホワイトノイズ的	平坦	ナイキストの半分あたり	大

特徴抽出による性能改善：瞬時周波数とスペクトルエントロピー



■ 瞬時周波数



■ スペクトルエントロピー

長さ9000の生データをセル分割
→ 255*2のデータ量に削減 (学習時間低減)

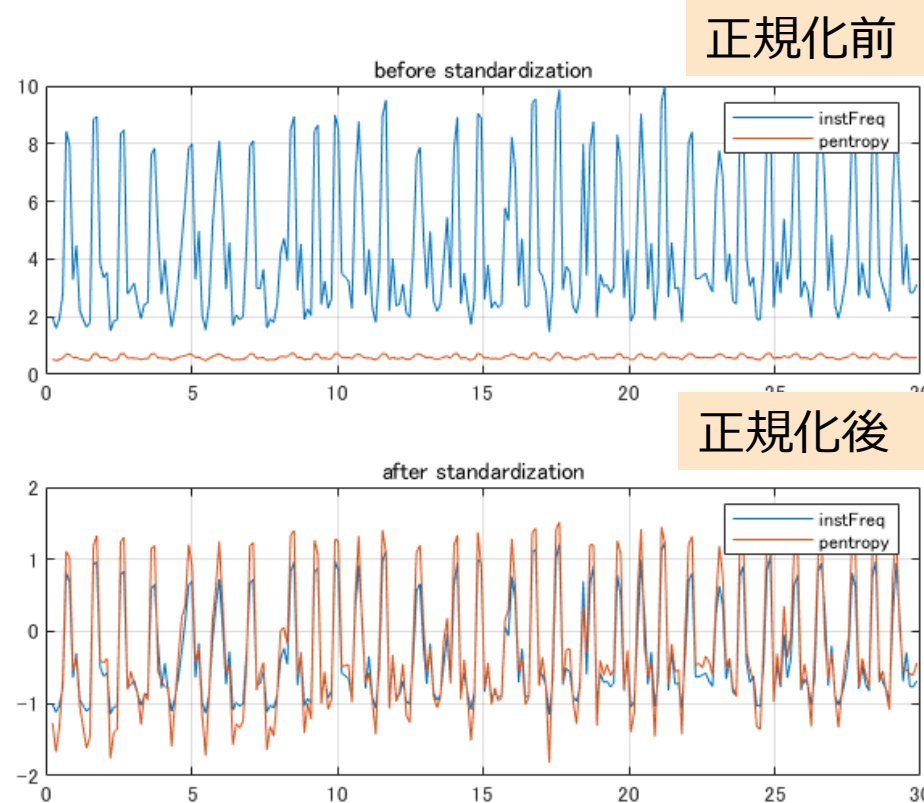
データの正規化

- LSTM内にtanh処理が含まれるため、入力は±1前後とするのが一般的
- この例の瞬時周波数とスペクトルエントロピーは、レベルが一桁程度違う（偏っている）

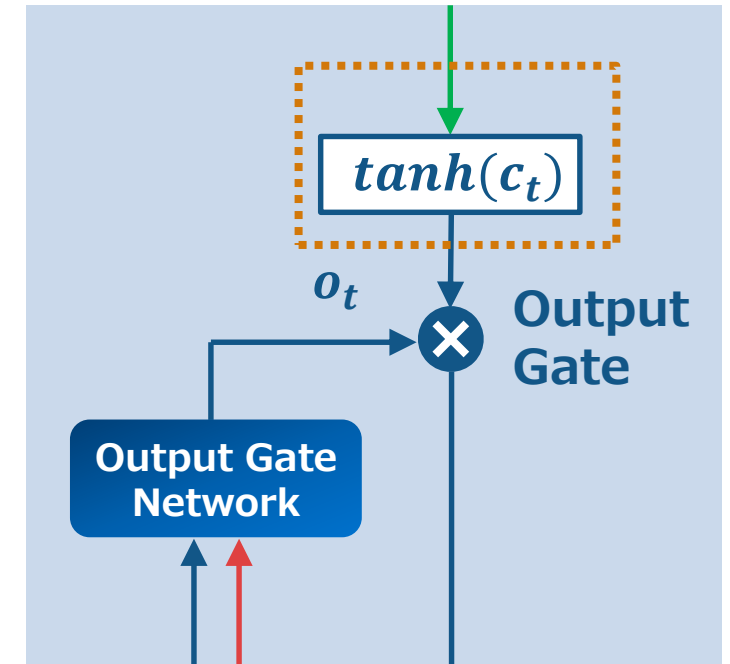
➔データの正規化を行う

```
>>XSD = (x-mu)./sg;
```

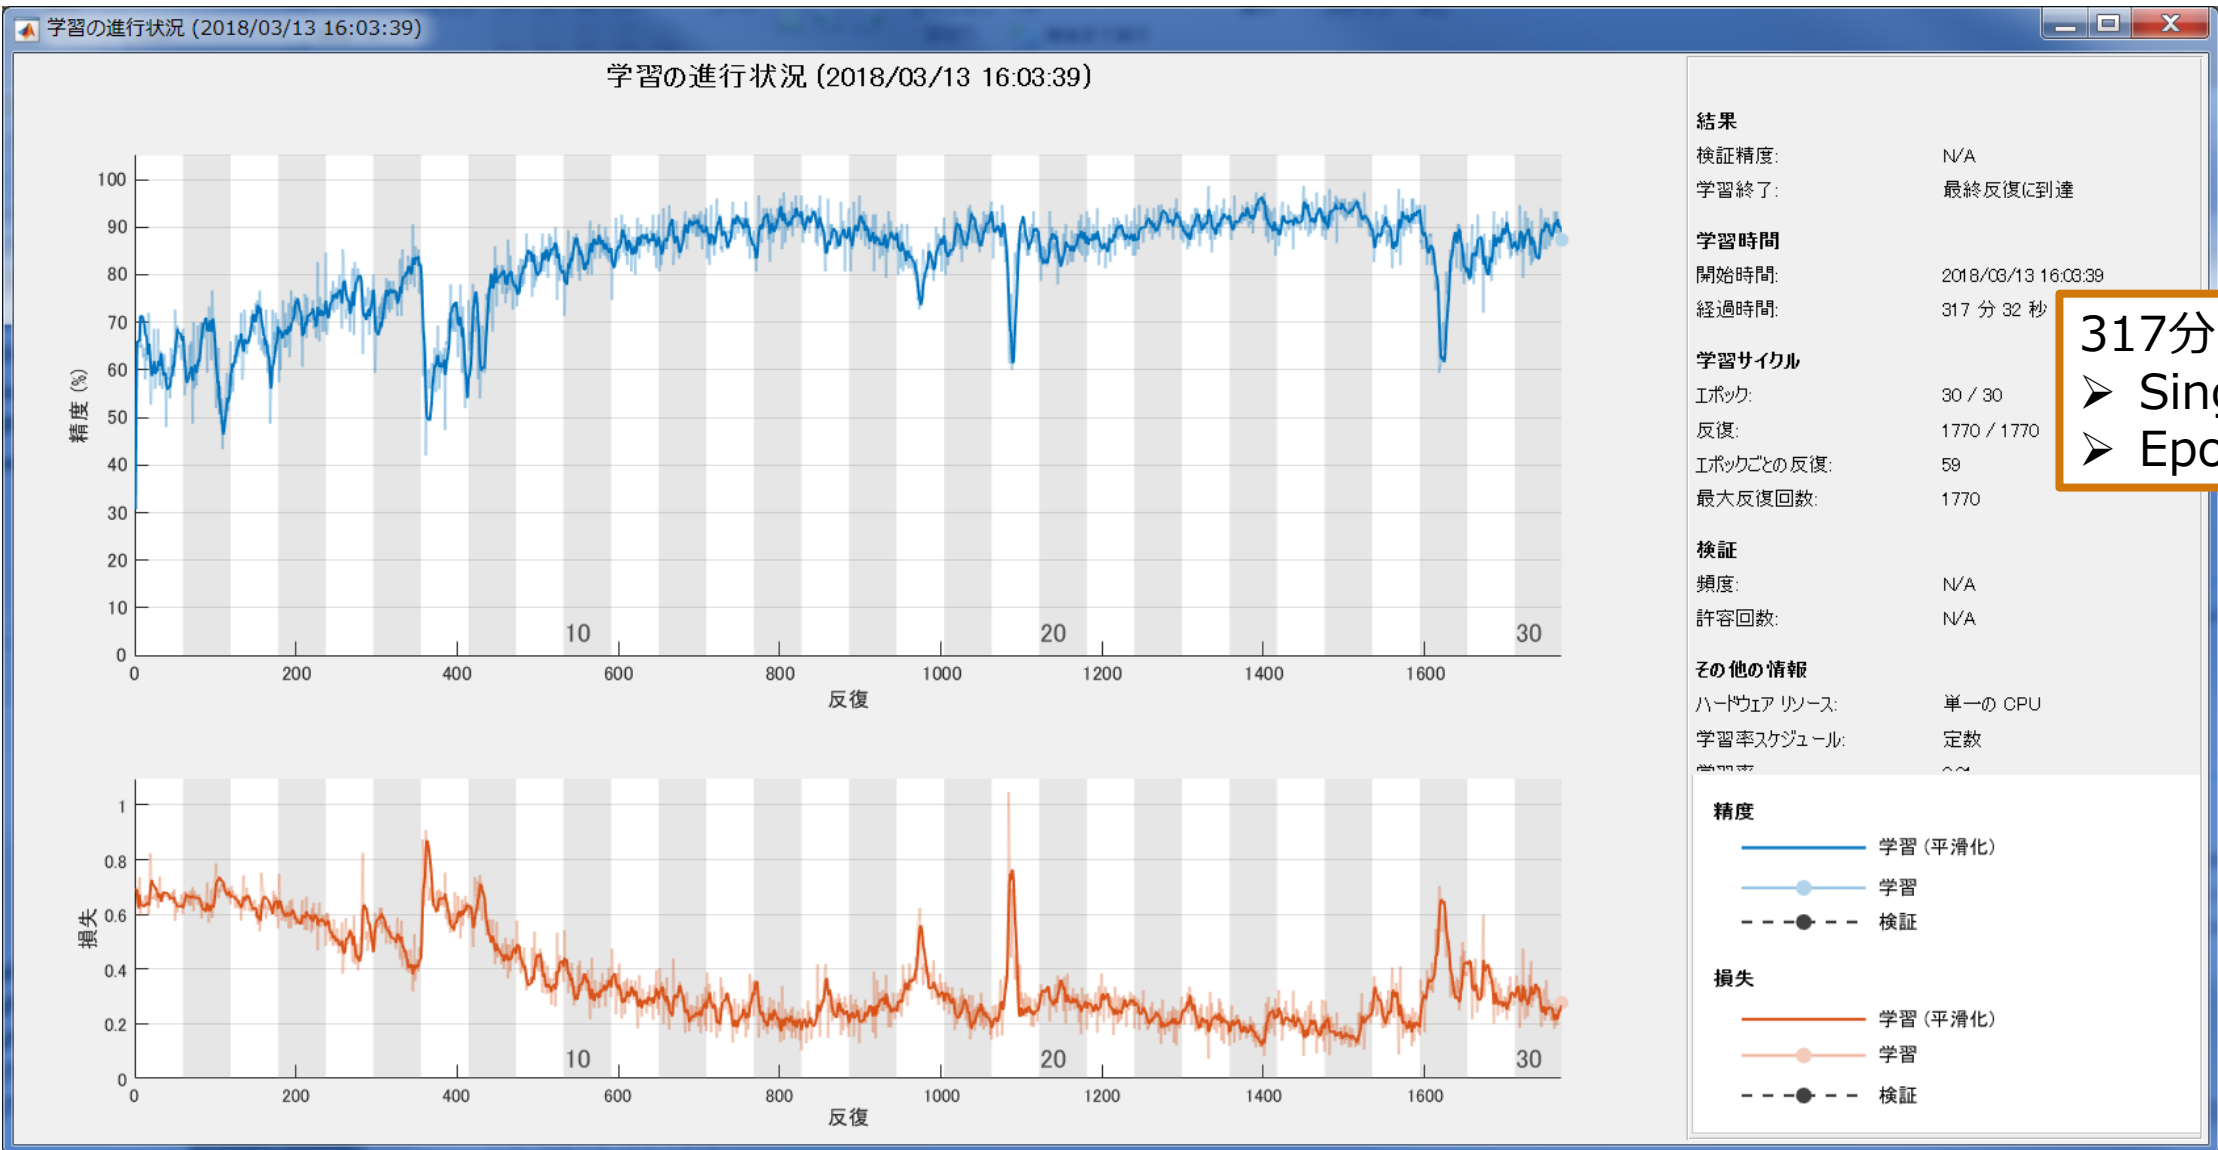
- x:データ
- mu:平均
- sg:標準偏差




LSTMブロック（一部）



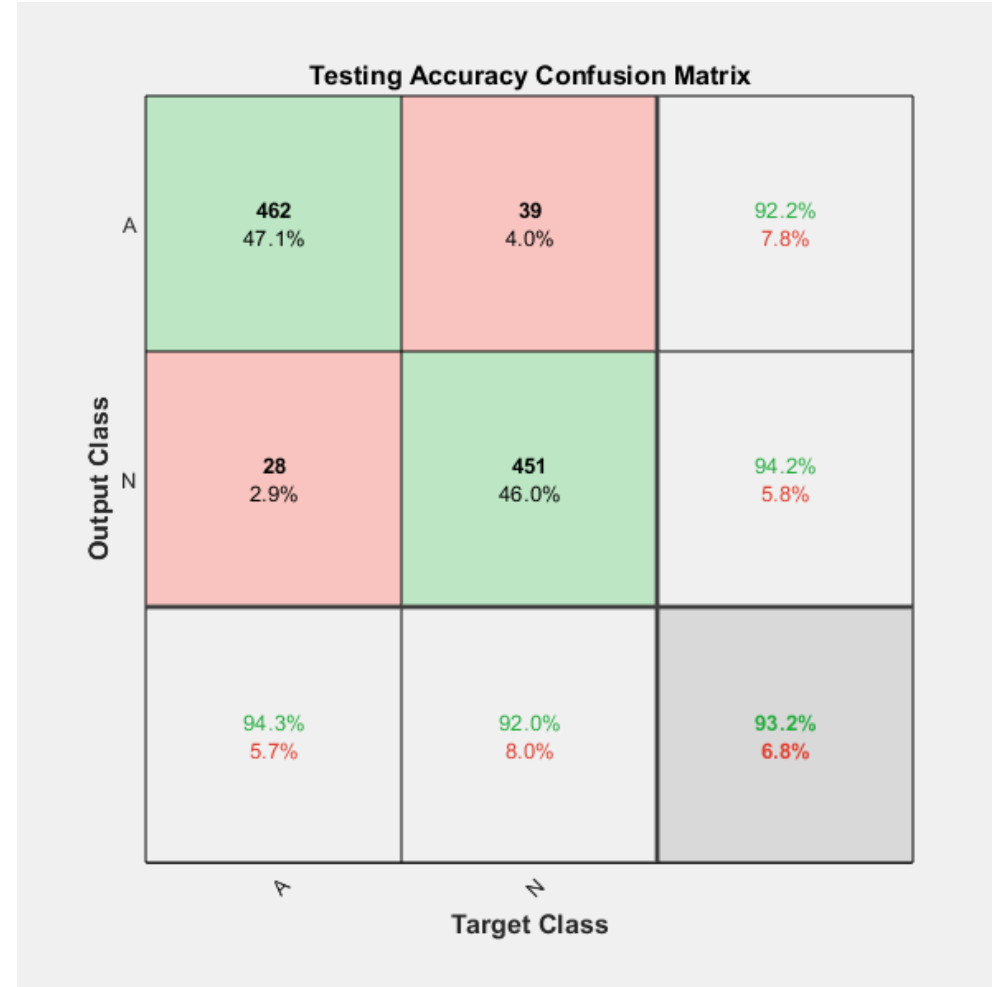
得られた二つの特徴量で再度学習



混合行列による評価



トレーニングデータ : 95.8%



テストデータ : 93.2%


結果 : 学習時間と学習精度の改善

参考：ウェーブレット解析とCNNを用いたEGC信号分類


R2018a

Wavelet Toolbox

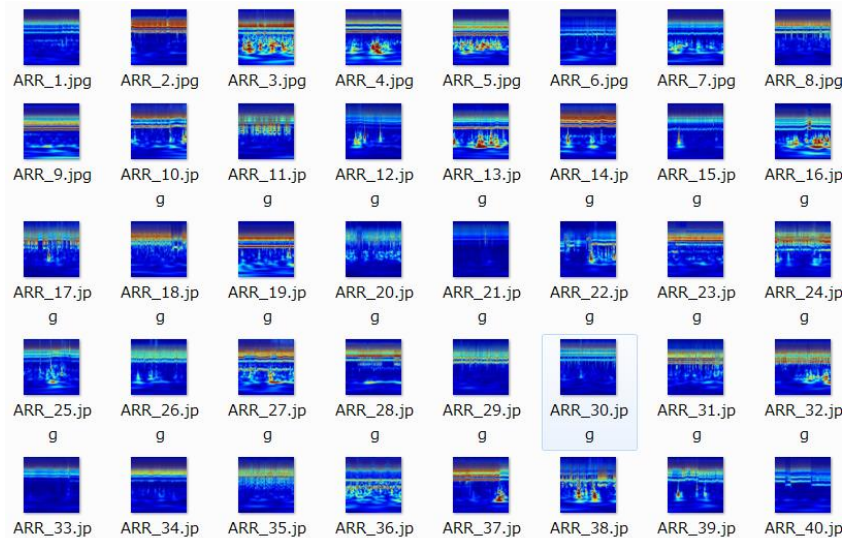

不整脈




心不全



正常



GoogLeNet





ECGのスカログラムを
画像データとして学習

AlexNet



二種類の学習済みネットワークで転移学習



参考 : MATLAB Tech Talks: Understanding Wavelet



Part 1: What Are Wavelets

Explore the fundamental concepts of wavelet transforms in this introductory MATLAB® Tech Talk by Kirthi Devleker.



Part 2: Types of Wavelet Transforms

Learn more about the continuous wavelet transform and the discrete wavelet transform in this MATLAB® Tech Talk by Kirthi Devleker.



Part 3: An Example Application of the Discrete Wavelet Transform

Learn how to use wavelets to denoise a signal while preserving its sharp features in this MATLAB® Tech Talk by Kirthi Devleker.



Part 4: An Example application of Continuous Wavelet Transform

Explore a practical application of using continuous wavelet transforms in this MATLAB® Tech Talk by Kirthi Devleker.

Waveletの原理から、
各種例題の実行手順を
動画で解説