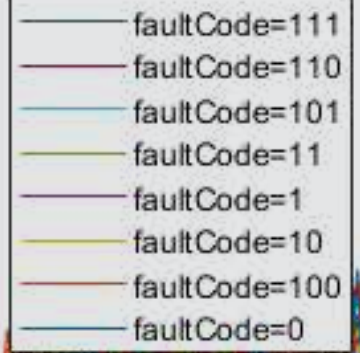



MATLAB による予知保全

目次

- 1.はじめに
- 2.状態インジケータの抽出
- 3.残存耐用時間の推定




パート 1: はじめに



予知保全とは？


私たちの生活は多くの機械によって支えられています。しかし、メンテナンスされないままではすべての機械はやがて故障を迎えることとなります。予知保全により機械がいつ故障するかを予測することが可能です。これによって事前にメンテナンスを計画し、在庫をより適切に管理し、計画外のダウンタイムを排除し、更には機器の寿命を最大化できます。



異なるメンテナンスアプローチ


事後保全

事後保全では機械は限界まで使用され、機械が故障した後のみ修理が実施されます。電球のような安価なシステムの維持には、事後アプローチを採用するのが理にかなっています。しかし、航空機のエンジンなどの非常に高価な部品を使用した複雑なシステムを考えてください。損傷の激しい部品の修理には莫大なコストが発生するため、故障するまで走らせるリスクを許容することは不可能です。それ以前のこととして安全性の確保が何よりも重要です。




予防保全

多くの組織は機器の定期的な検査を行うことにより故障を未然に防ごうとします。予防保全に関する大きな課題の一つは保守時期の決定です。故障の発生時期を正確に知りえないため、特に故障発生が許されないような機器の稼働に関して余裕をもった保守計画をすることになります。しかし、メンテナンスをかなり早期にスケジュールすることで本来はまだ使用可能な機械の稼働時間を無駄にすることにつながり結果としてコストが増加します。



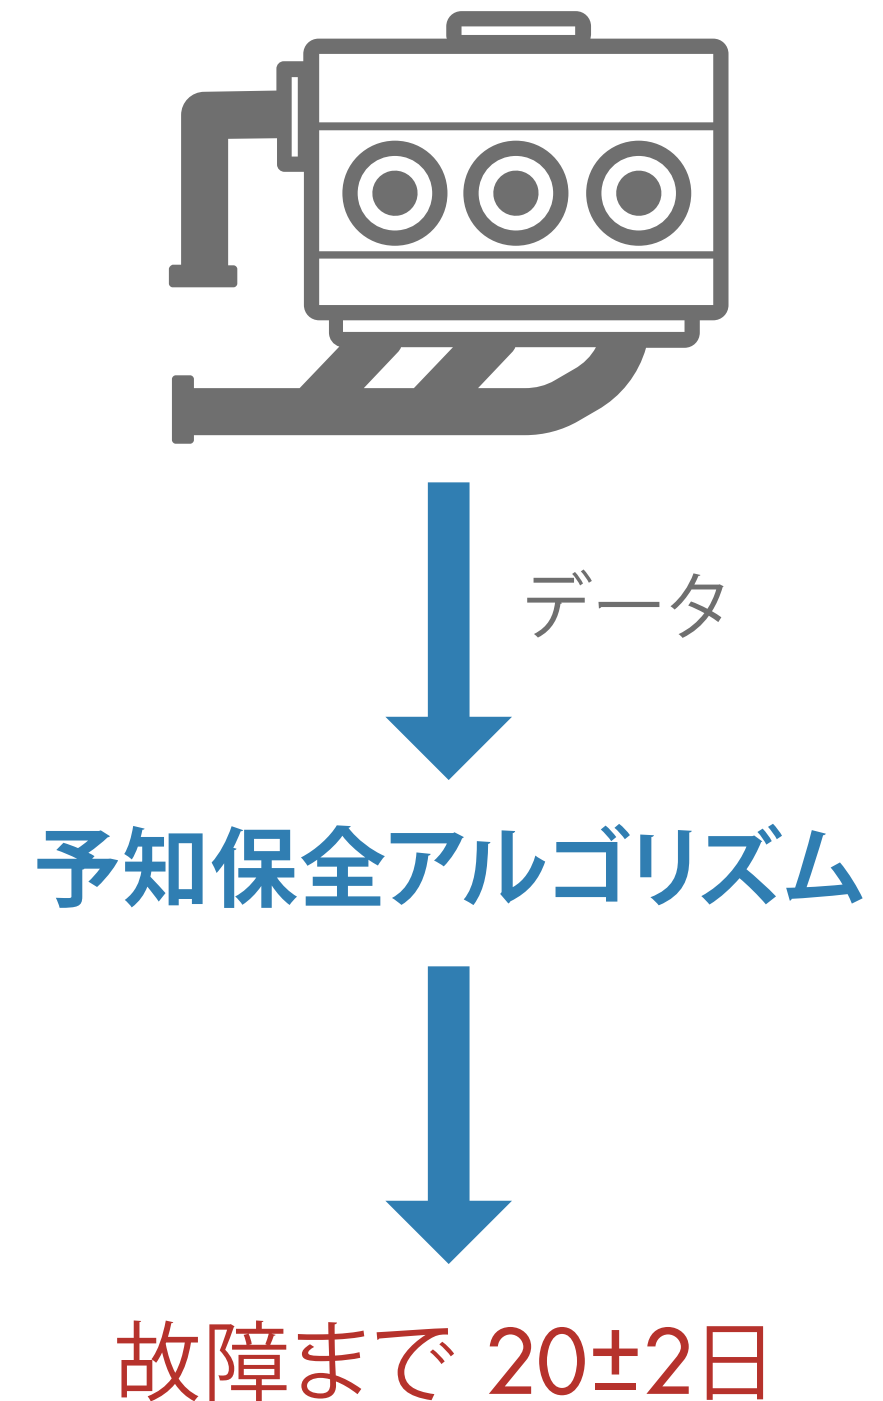
予知保全

予知保全によって機械が故障するまでの時間を見積もることができます。故障時期を予測することによって機器のメンテナンスを行う最適な時期を見つけてスケジュールを立てることが可能になります。予知保全は将来の故障を予測するだけでなく、複雑な機器の問題箇所と修繕が必要な部品の特定にも役立ちます。



予知保全に着手

予知保全の実施はダウンタイムの削減、スペアパーツ在庫量の適正化、機器寿命の最大化に貢献します。しかし、何から始めればよいのでしょうか？まず最初に機械の故障が発生してメンテナンスが必要となる時期を（例えば日数単位で）予測するアルゴリズムを開発する必要があります。アルゴリズム開発に取りかかるために予知保全ワークフローを見てみましょう。



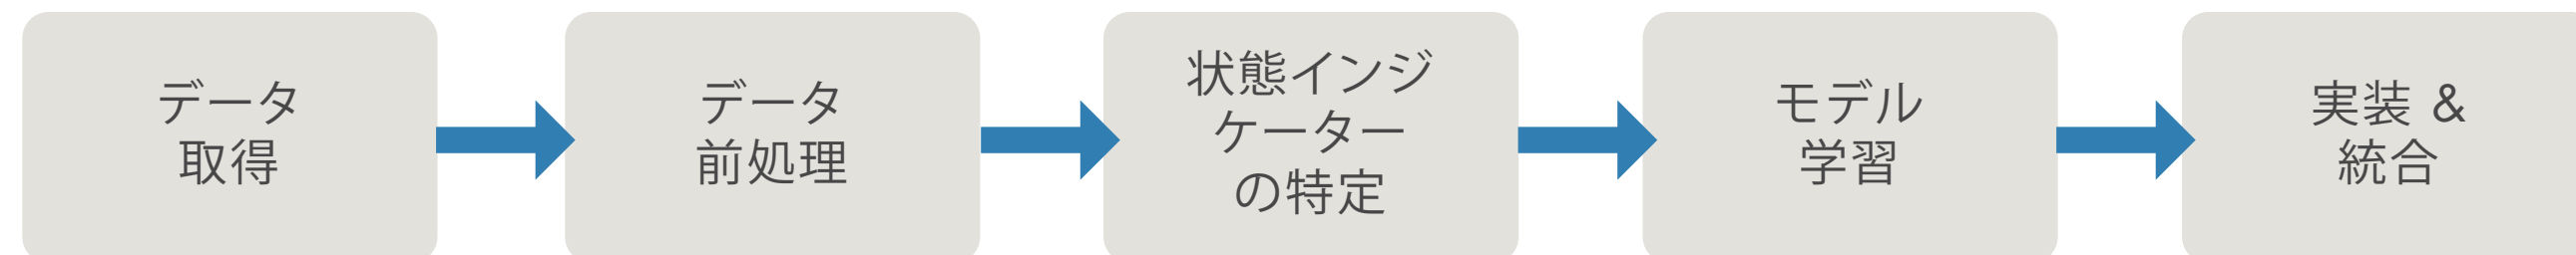
予知保全のワークフロー概要

アルゴリズムの開発には、システムの状態を正常・異常に区別する**データ**が必要になります。機器の**状態を示すインジケータ**を抽出するためには、生データの**前処理**が必要です。状態インジケータとは、状態を正常と異常とに区別するのに役立つ特徴量です。その後、抽出された特徴量を使用して**機械学習モデルを学習**させることで以下のことが可能となります。


- 異常検出
- 異常を異なるタイプに分類
- 機械の残存耐用時間の推定

最後にアルゴリズムを**実装**し、機械の監視とメンテナンスを担うシステムに**統合**します。

次のセクションでは、3筒型ポンプの例を使用してワークフローの手順を説明します。3筒型ポンプは石油・ガス業界で一般的に使用されています。

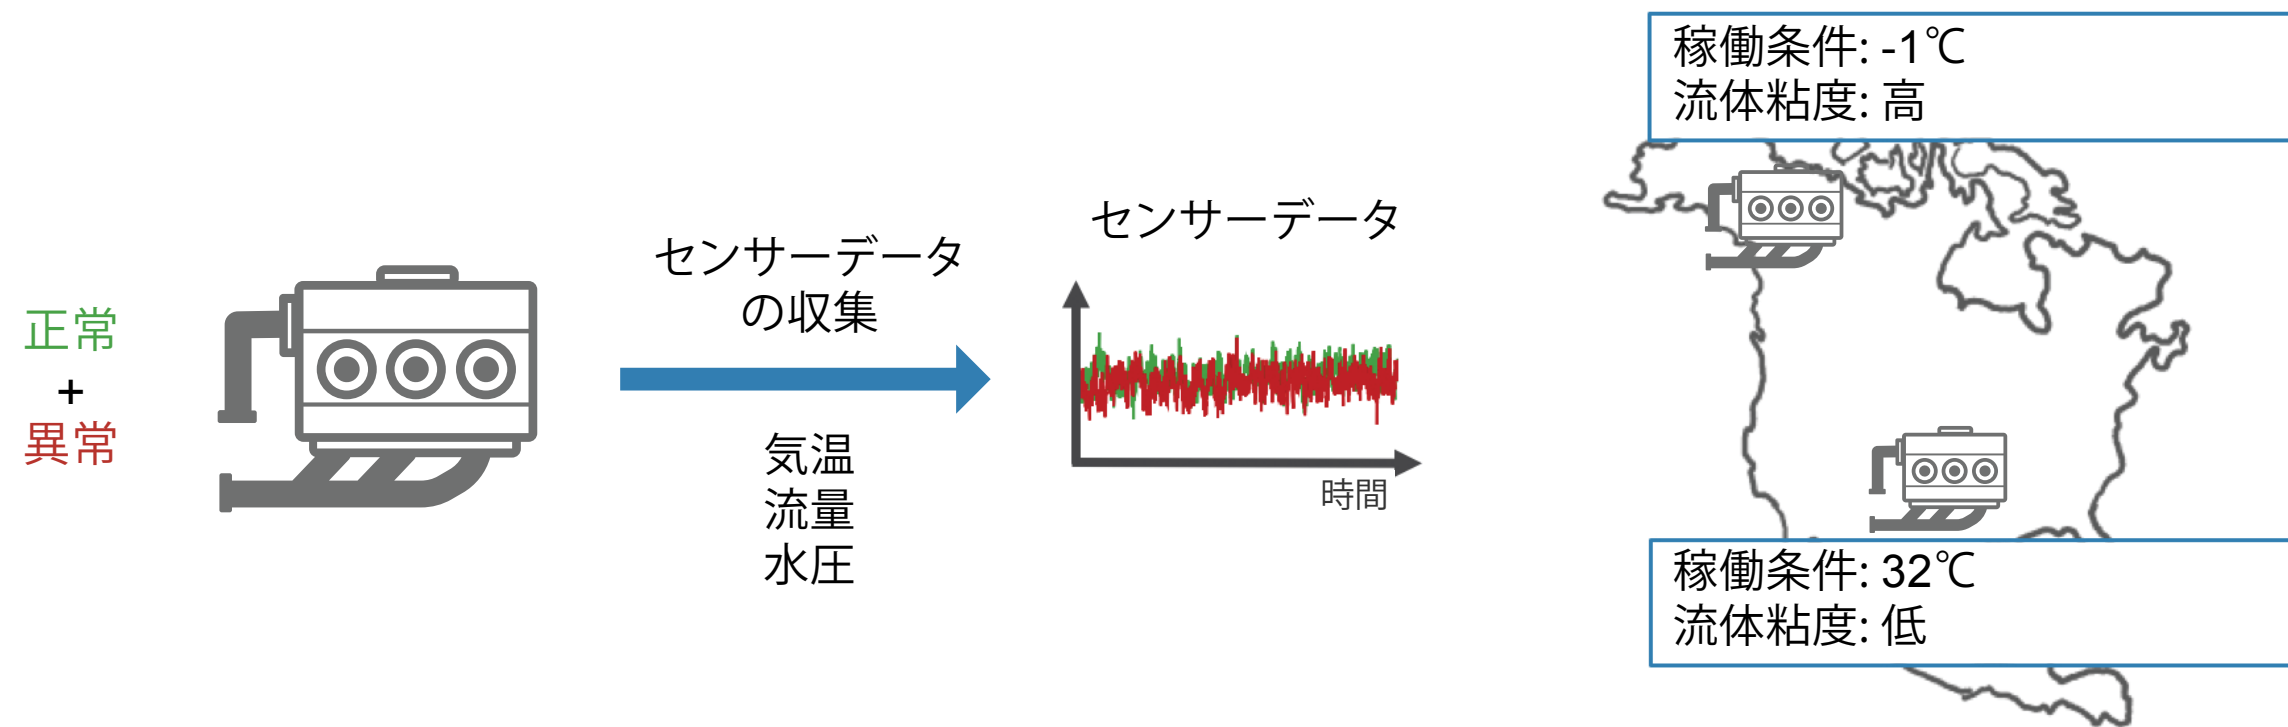


データの取得



最初のステップは、稼働状況の**正常・異常**を捉えた**大規模なセンサーデータを収集**することです。さまざまな稼働条件下でのデータを収集することが重要です。例えば、アラスカとテキサスで場所は違っても同じタイプのポンプを使用している場合があります。一方では粘度の高い液体を汲み上げ、もう一方では粘度の低い液体を扱っているかもしれません。同じタイプ

のポンプを使用している場合、このように**稼働条件**が異なれば、一方が他方より早く故障する場合があります。可能な限り多くのデータを収集することで、高い精度で異常を検出する**信頼性の高いアルゴリズム**を開発することができます。




注: この例では説明を単純化するために、正常と異常を示す稼働状況を単一の測定値で表しています。実際には稼働状況の把握に何百もの測定値を用いることがあります。

データの取得 (続き)



正常と異常を表すデータが不足しているケースも考えられます。代替的な手段として**ポンプの数学的モデル**を構築し、センサーデータからパラメータを推定することができます。その後、さまざまな稼働条件下と異なる異常状態でモデルのシミュレーションを行い、**異常データを生成**することが可能です。このデータは**合成データ**とも呼ばれ、センサーデータを補足します。合成データとセンサーデータを組み合わせることで予知保全アルゴリズムを開発することができるようになります。

さらに詳しく: [Simulink による異常データの生成](#)



異なる故障条件下でモデルをシミュレーションし、異常データを生成

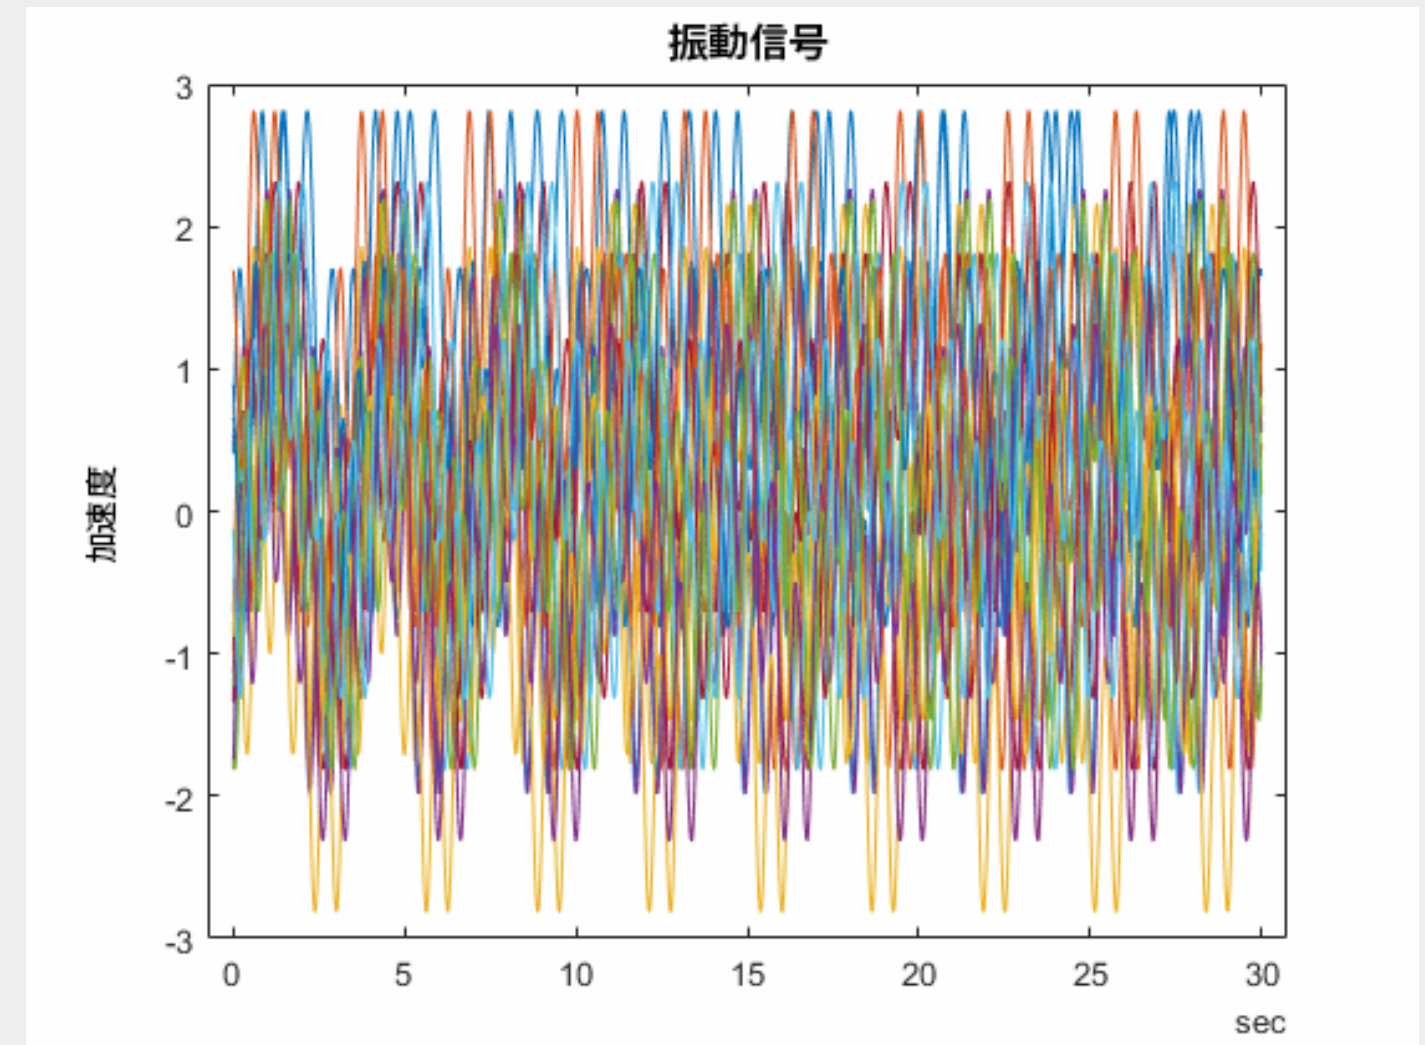
MATLAB によるデータの取得

機器からのデータは構造化されている場合とそうでない場合があります。ローカルファイル、クラウド (AWS® S3、Azure® Blob など)、データベース、データヒストリアンなどの複数のソースに置かれています。データがどこにあっても、MATLAB® を使用してデータにアクセスできます。十分な故障データがない場合でも、信号故障を挿入してシステム故障のダイナミクスをモデル化することで、機器の Simulink® モデルからデータを生成できます。

「MATLAB は、従来読みこむことができなかったデータを、読み込みやすく使いやすい形式に変換し、フィルタリング、スペクトル分析、そして複数のトラックや地域毎に異なる手順の自動化や、最終的には機械学習技術をリアルタイムに適用してメンテナンスを行う最適なタイミングを予測する能力をもたらしました。」


— Baker Hughes, Gulshan Singh 氏

» [ユーザー事例を読む](#)




Simulink で生成された伝送モデルの合成異常データ

データの前処理



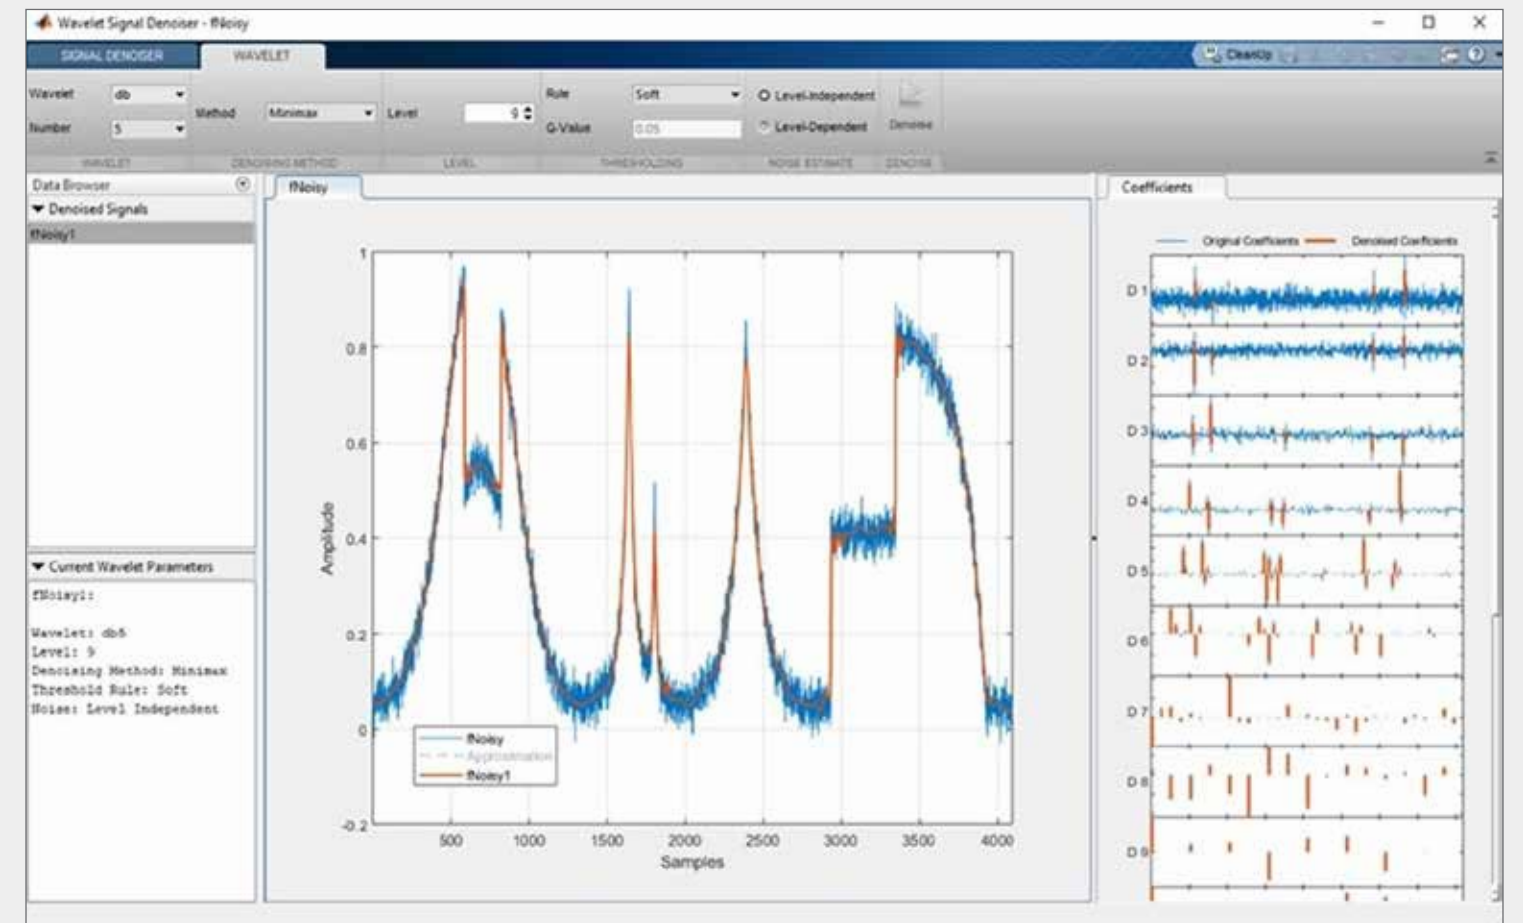
データを取得したら、次のステップとして**データを前処理**して、状態インジケータを容易に抽出できる形に変換します。前処理には、**ノイズ、外れ値、欠損値の除去**などの手法が含まれます。元のデータのままだでは分かりにくい情報を明らかにするために、さらなる前処理が必要になる場合があります。たとえば、下記の前処理の例では時間領域データから**周波数領域**への変換が含まれます。



MATLAB によるデータの前処理

大抵の場合、データがきれいに整った状態で手に入ることはありません。MATLAB を使用して前処理、次元の削減、および特徴量の設計を行います。

- 異なるレートでサンプリングされたデータを調整し、欠損値と外れ値を考慮
- 高度な信号処理手法を使用したノイズの除去、データのフィルタ処理および過渡信号または変化信号の解析
- 特徴量の抽出および選択のための統計および動的解析を使用したデータセットの簡略化と予測モデルの過適合の削減




ウェーブレット信号デノイザーアプリによる信号の視覚化、ノイズ除去、結果の比較

状態インジケータの特定



次のステップでは、システムが低下するにつれてある特徴量の挙動が予測可能な方法で変化する**状態インジケータ**を識別します。これらの特徴量は、**正常な動作と異常な動作を区別**するために使用されます。

右のプロットでは、ポンプが劣化すると周波数データのピークが左にシフトするため、ピーク周波数は状態インジケータとして機能します。

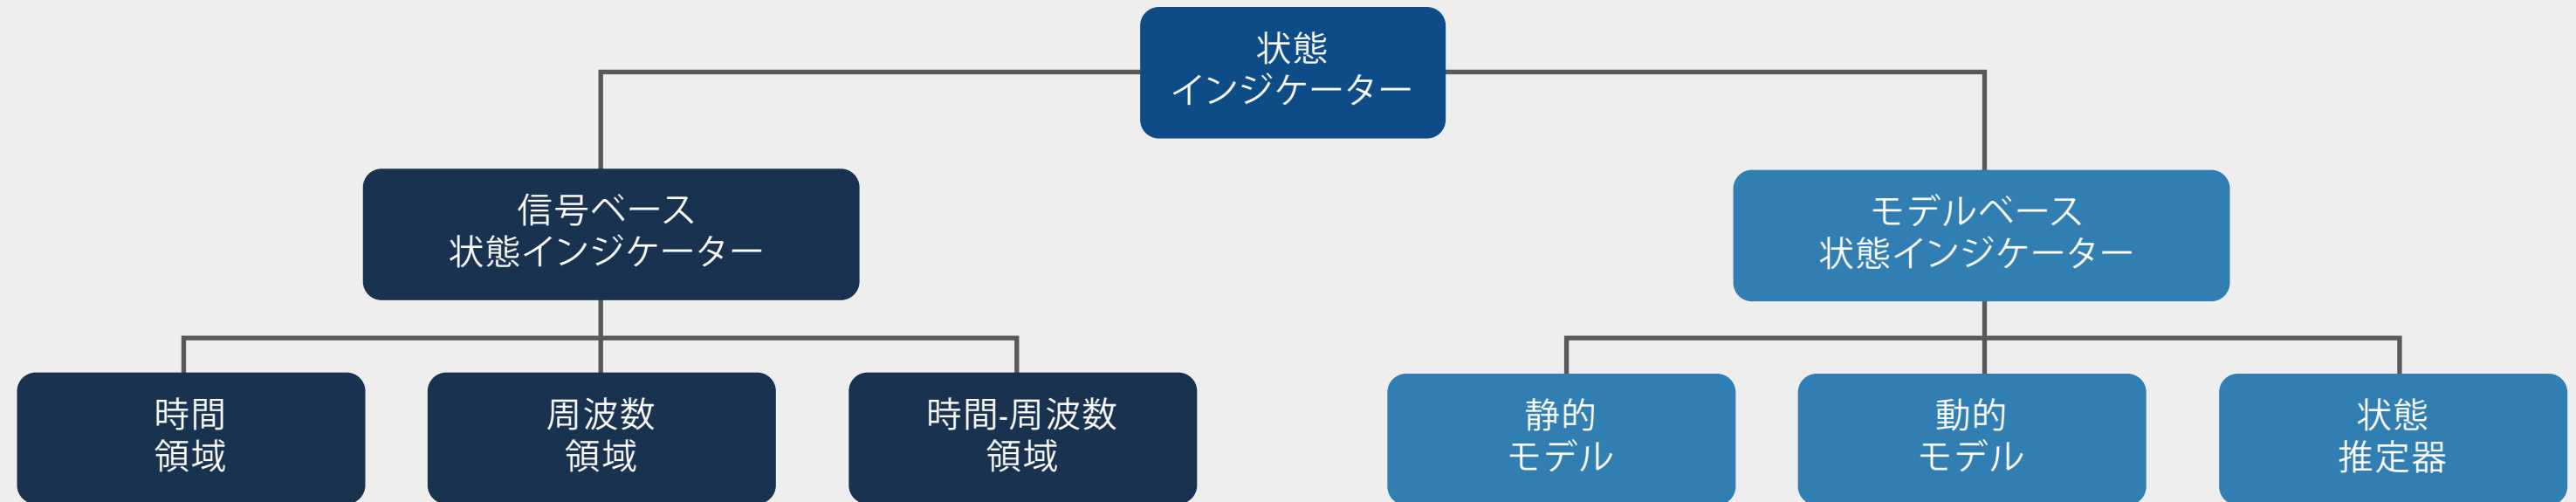


ピーク周波数が状態インジケータとして機能している

MATLAB を使用した状態インジケータの特定


MATLAB と Predictive Maintenance Toolbox™ では、信号ベースおよびモデルベースのアプローチによって状態インジケータを設計できます。振動データを分析する際によく見られる時間変化する特性を表現するのに、例えば時間-周波数モーメントを計算することも可能です。非線形の動作または特性をもつ機器の突然の変化を検出するために、時間の経過に伴うシステムの状態の変化を追跡する位相空間再構成に基づいた特徴量も有効です。

さらに詳しく: [Predictive Maintenance Toolbox の機能紹介 \(ビデオ\)](#)



信号ベースおよびモデルベースの手法を使用して、機械の状態を監視する状態インジケータを設計

モデルの学習



ここまでで、ポンプの正常な動作と異常な動作を理解するのに必要なデータからの特徴量の抽出が完了しました。しかし、この段階ではどの部品を修理する必要があるか、または故障が発生するまでの時間についてはまだ明らかになっていません。次のステップでは、抽出された特徴量を使用して**機械学習モデルを学習**させます。

異常検知

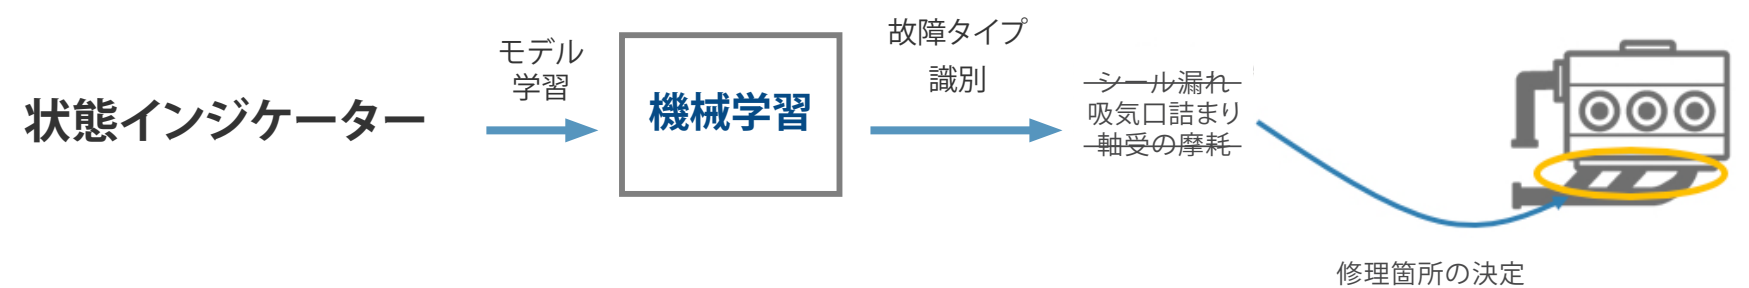
システム内の変化を追跡して異常の有無を判断することが可能です。

さらに詳しく: [メルセデスベンツにおけるパワートレイン製造設備の異常検出](#)



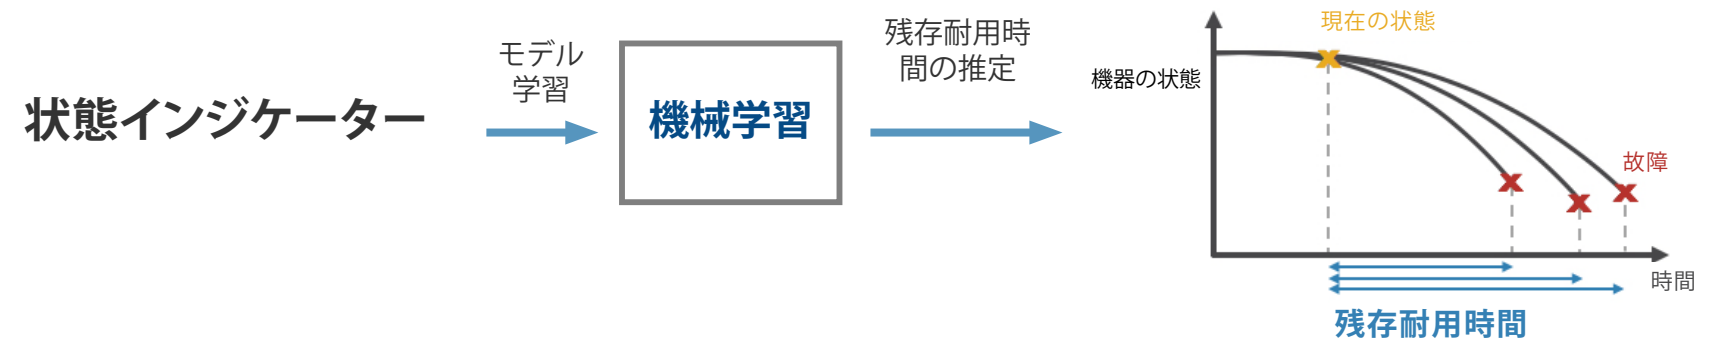
分類による異なるタイプの故障検出

ポンプのどの部分に注意すべきなのかを知ることができます。



正常な状態から異常な状態への遷移の予測

抽出された特徴量とポンプの劣化経路との関係を把握するモデルを見つけることは、故障までの時間 (**残存耐用時間**) とメンテナンスのスケジュール時期の見積りに役立ちます。

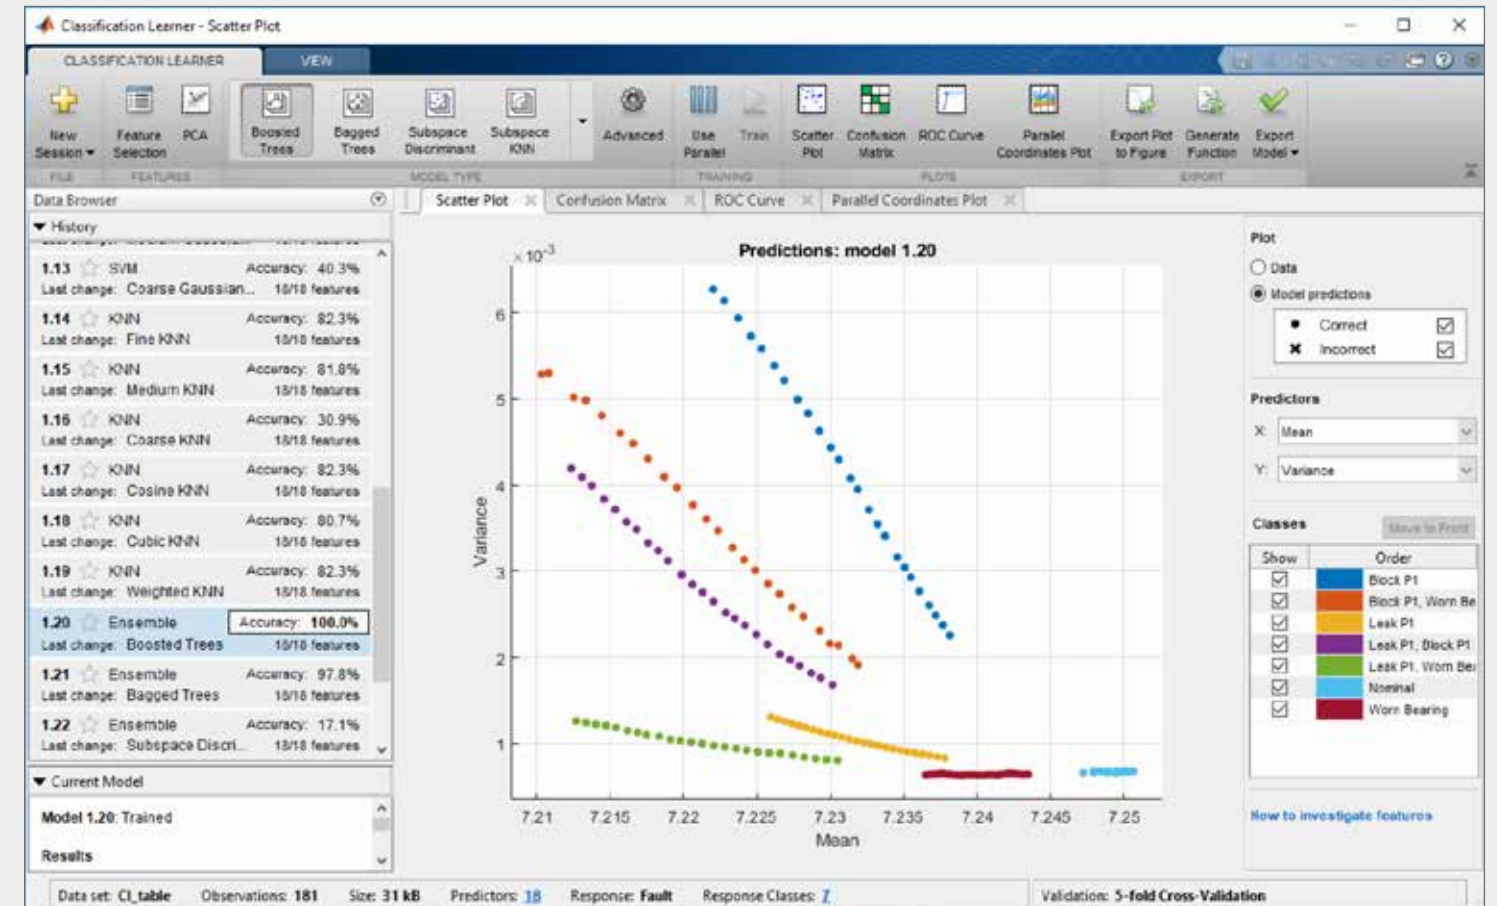


さらに詳しく: [MATLAB で残存耐用時間 \(RUL\) を予測する 3 つの方法](#)

MATLAB による機械学習を使用したモデルの学習

分類、回帰、および時系列モデリング手法を用いて、故障の根本原因を特定し、故障発生までの時間を予測できます。

- 残存耐用時間 (RUL) の推定または故障モードの分類に最も重要と考えられる変数を対話的に探索して選択
- 組み込み関数を使用して、複数の予測モデルを学習、比較、および検証
- 信頼区間の計算と可視化による予測の不確実性の定量化



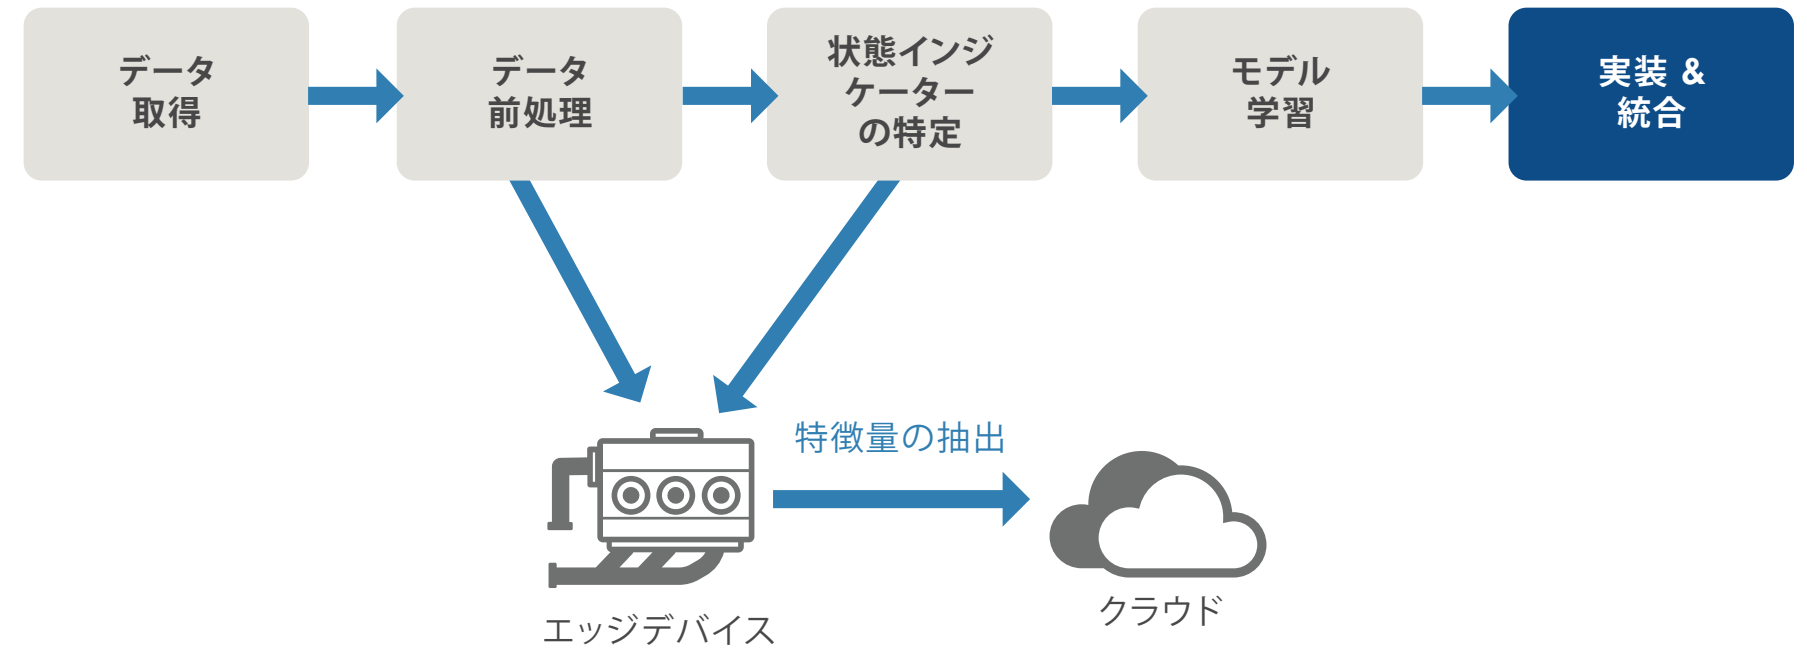
分類学習器アプリを使ってさまざまな分類器を評価し、決定木やサポートベクターマシンなどの一般的なモデルから最適なものを見つけることが可能

実装と統合

アルゴリズムを開発した後は、**クラウド**または**エッジデバイス**に**展開**することが可能です。クラウドへの実装は、クラウド上で大量のデータを収集および格納する場合に有効です。

その他の方法として、アルゴリズムを組み込みデバイスなど実際の機器に近い場所で実行することもできます。インターネット接続が利用できない場合なども対象になります。

3番目のオプションは、上記2つを組み合わせることで、データが大規模で送信できるデータ量が制限される場合は、エッジデバイス側で前処理と特徴量抽出の手順を実行し、抽出された特徴量のみをクラウド上の予測モデルに送ることができます。



MATLAB による運用システムへのアルゴリズム展開

データサイエンティストは、結果を共有し説明する能力のことをモデルの解釈可能性と呼ぶことがあります。解釈が容易なモデルには以下のような特徴があります。

- システムの物理的な理解から作られる少数の特徴
- 透明性の高い意思決定プロセス

解釈可能性は以下の必要を満たすことが期待されるアプリケーションにおいて重要です。

- モデルが政府の規格や業界標準に準拠していることを証明する必要
- 診断に寄与した要因を説明する必要
- 意思決定にバイアスがないことを示す必要

「我々はクリスマスの期間でさえも休むことなく機械を動かしていますが、MATLAB ベースの監視/予知保全ソフトウェアのおかげで、中断のない安定した運用が可能になっています。」

— Mondy, Michael Kohlert 博士

» [ユーザー事例を読む](#)



スタンドアロンの MATLAB アプリケーションを共有するか、Web、データベース、デスクトップおよびエンタープライズ アプリケーションの一部として MATLAB の解析を実行。カスタムのインフラストラクチャーを構築する必要はありません。

さらに詳しく

見る

[MATLAB/Simulink による予知保全 \(ビデオシリーズ\)](#)

読む

[実例に学ぶ予知保全向けデータ活用 \(ホワイトペーパー\)](#)

[予知保全で直面しやすい 4 つの課題とその対処法 \(ホワイトペーパー\)](#)

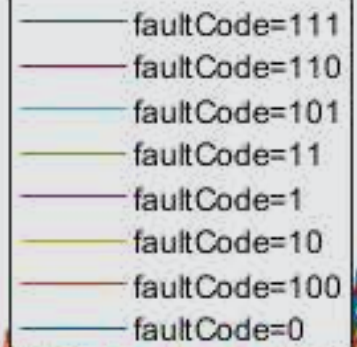
[予知保全・異常検知を可能にする特徴量 \(ホワイトペーパー\)](#)

その他

[MATLAB による予知保全 \(コード例\)](#)

[Predictive Maintenance Toolbox \(製品ページ\)](#)

[予知保全向け MATLAB 無料評価版のダウンロード](#)






パート 2: 状態インジケータの抽出

■ 状況インジケータとは


予知保全アルゴリズム開発で重要となる手順は、状況インジケータの特定です。それはシステムの劣化とともに予知できる形で挙動が変化する、システムの特徴です。状況インジケータは故障と正常な動作との区別に役立ちます。前処理されたシステムデータからそれらを抽出し、故障分類と残存耐用時間 (RUL) の推定に使用します。



視覚的な演習

視覚的に状況インジケータの機能を理解しましょう。これらの2つの形状の違いは何でしょう？

円



2つの円はほとんど同じに見えるため、大きな違いはないように見えます。

視覚的な演習 - 続き

前のページでは、特定の角度、つまり上方視点から見ていたため形状は同じに見えました。しかし、視点を変えてみると、2つの形状の違いが明らかになり、円錐と円柱に識別できます。

円錐



円柱



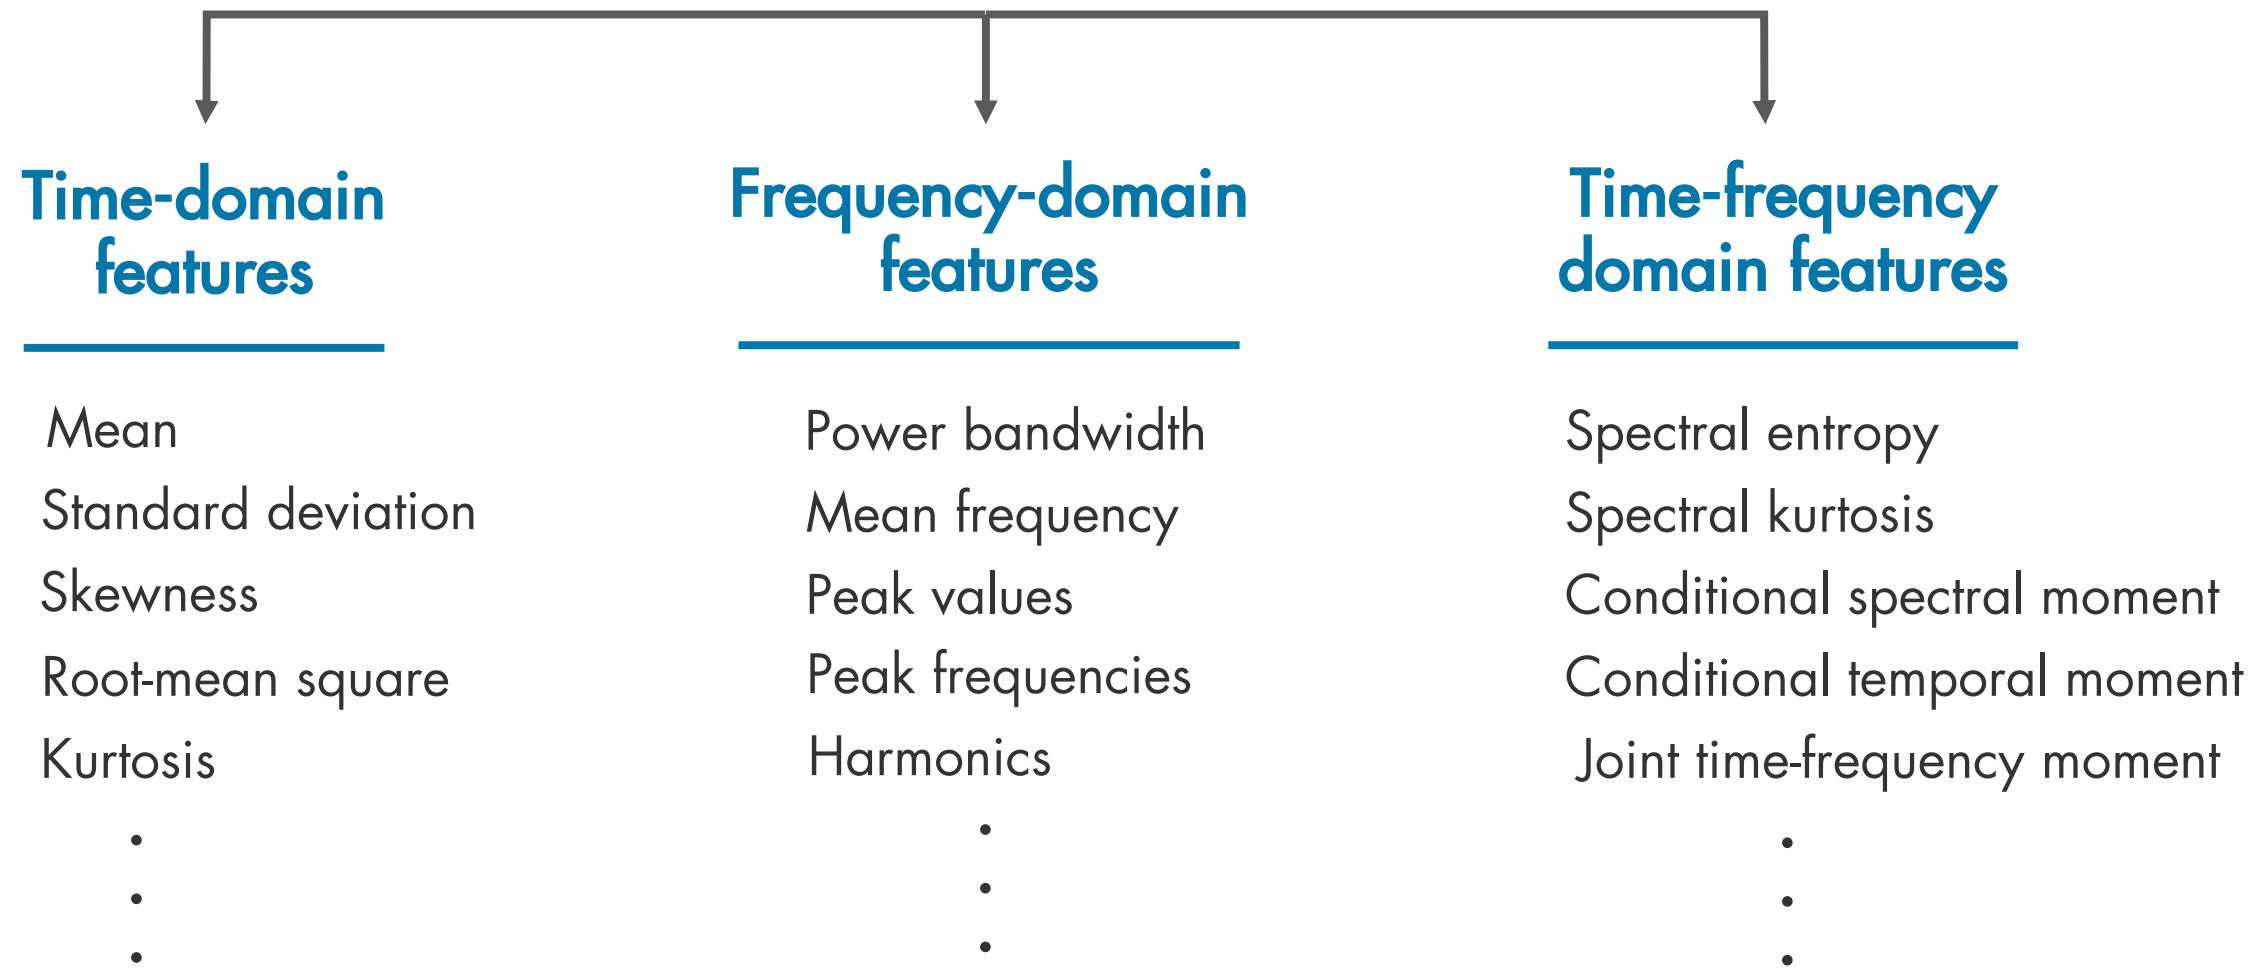
同様に、機械からの生の測定データを見たときも、故障と正常な動作を区別することは困難です。しかし、状況インジケータを使用することにより、データを違う視点から見るのが可能になり、正常な動作と故障の区別に役立ちます。



信号ベースの手法を使用した特徴抽出

時間領域、周波数領域、時間周波数領域の特徴を使用して、データから状況インジケータを算出することができます。


Signal-Based Condition Indicators



信号ベースの手法を使用した特徴抽出 - 続き


時間領域の特徴

いくつかのシステムでは、時間信号の単純な統計的特徴が、正常なものから故障状態を区別する状況インジケータとして機能します。たとえば、特定の信号の平均値、またはその標準偏差がシステムが劣化するにつれ変化することがあります。歪度や尖度などの、信号の高次モーメントを使用することもできます。それらの特徴を用いて、正常動作と故障動作を区別するしきい値を特定する、またはシステム状態の変化を示す値の突然の変化を探ることができます。



連続する50日間での風力タービン高速シャフトの劣化を示す、時間領域での振動信号の傾向変化。

MATLAB® のアドオン製品である Predictive Maintenance Toolbox™ には、タービンでの高速ベアリングの故障予測の例でも扱われている、時間領域の特徴を算出する追加の関数が提供されています。



異なった時間領域および周波数領域での、特徴の重要度ランキングを表すグラフ。

信号ベースの手法を使用した特徴抽出 - 続き

周波数領域の特徴




時間領域の特徴のみでは状況インジケータとして十分に機能しないことがあり、周波数領域の特徴も調べたくなります。

回転コンポーネントに加えベアリング、モーターシャフト、およびディスクの3つの振動源を持つ機械を例に取りましょう。機械からの時間領域における振動データを見ると、これらの異なる回転コンポーネントからの振動が混合した影響を見ることができます。しかし、周波数領域でのデータ

を解析すると、2つ目のプロットのように、異なる振動源を分離することができます。最大振幅、およびノミナル値からの変化幅で、故障の深刻度を特定することができます。

周波数領域での状況インジケータの算出についての詳細は、[振動信号を使用した状況監視と予測](#)の例を参照してください。

Machine with rotating components



時間領域で機械からの振動データを解析するとき、ベアリング、モーターシャフト、およびディスクのすべてが振幅に影響を与えます。周波数領域の解析を使用することにより、異なる振動源を区別できます。


信号ベースの手法を使用した特徴抽出 - 続き

時間周波数領域の特徴

特徴を抽出するもう一つの方法は、信号のスペクトル成分の時間変化を特徴づける時間周波数スペクトル解析を行う方法です。時間周波数領域の状況インジケータには、スペクトル尖度やスペクトル エントロピーなどが含まれます。

回転要素ベアリングの故障分析の例では、kurtogram、スペクトル尖度、および包絡線スペクトルを使用して、回転要素ベアリングでの異なる故障タイプを識別する方法を紹介しています。

» [時間、周波数、時間周波数領域における信号解析の詳細を知る](#)




ベアリングの3つの状態を明確に区別するヒストグラム。ベアリングの故障を分類する有効な特徴である、インナーレースのバンドパス周波数とアウトレース振幅の対数比率。

予知保全ワークフロー

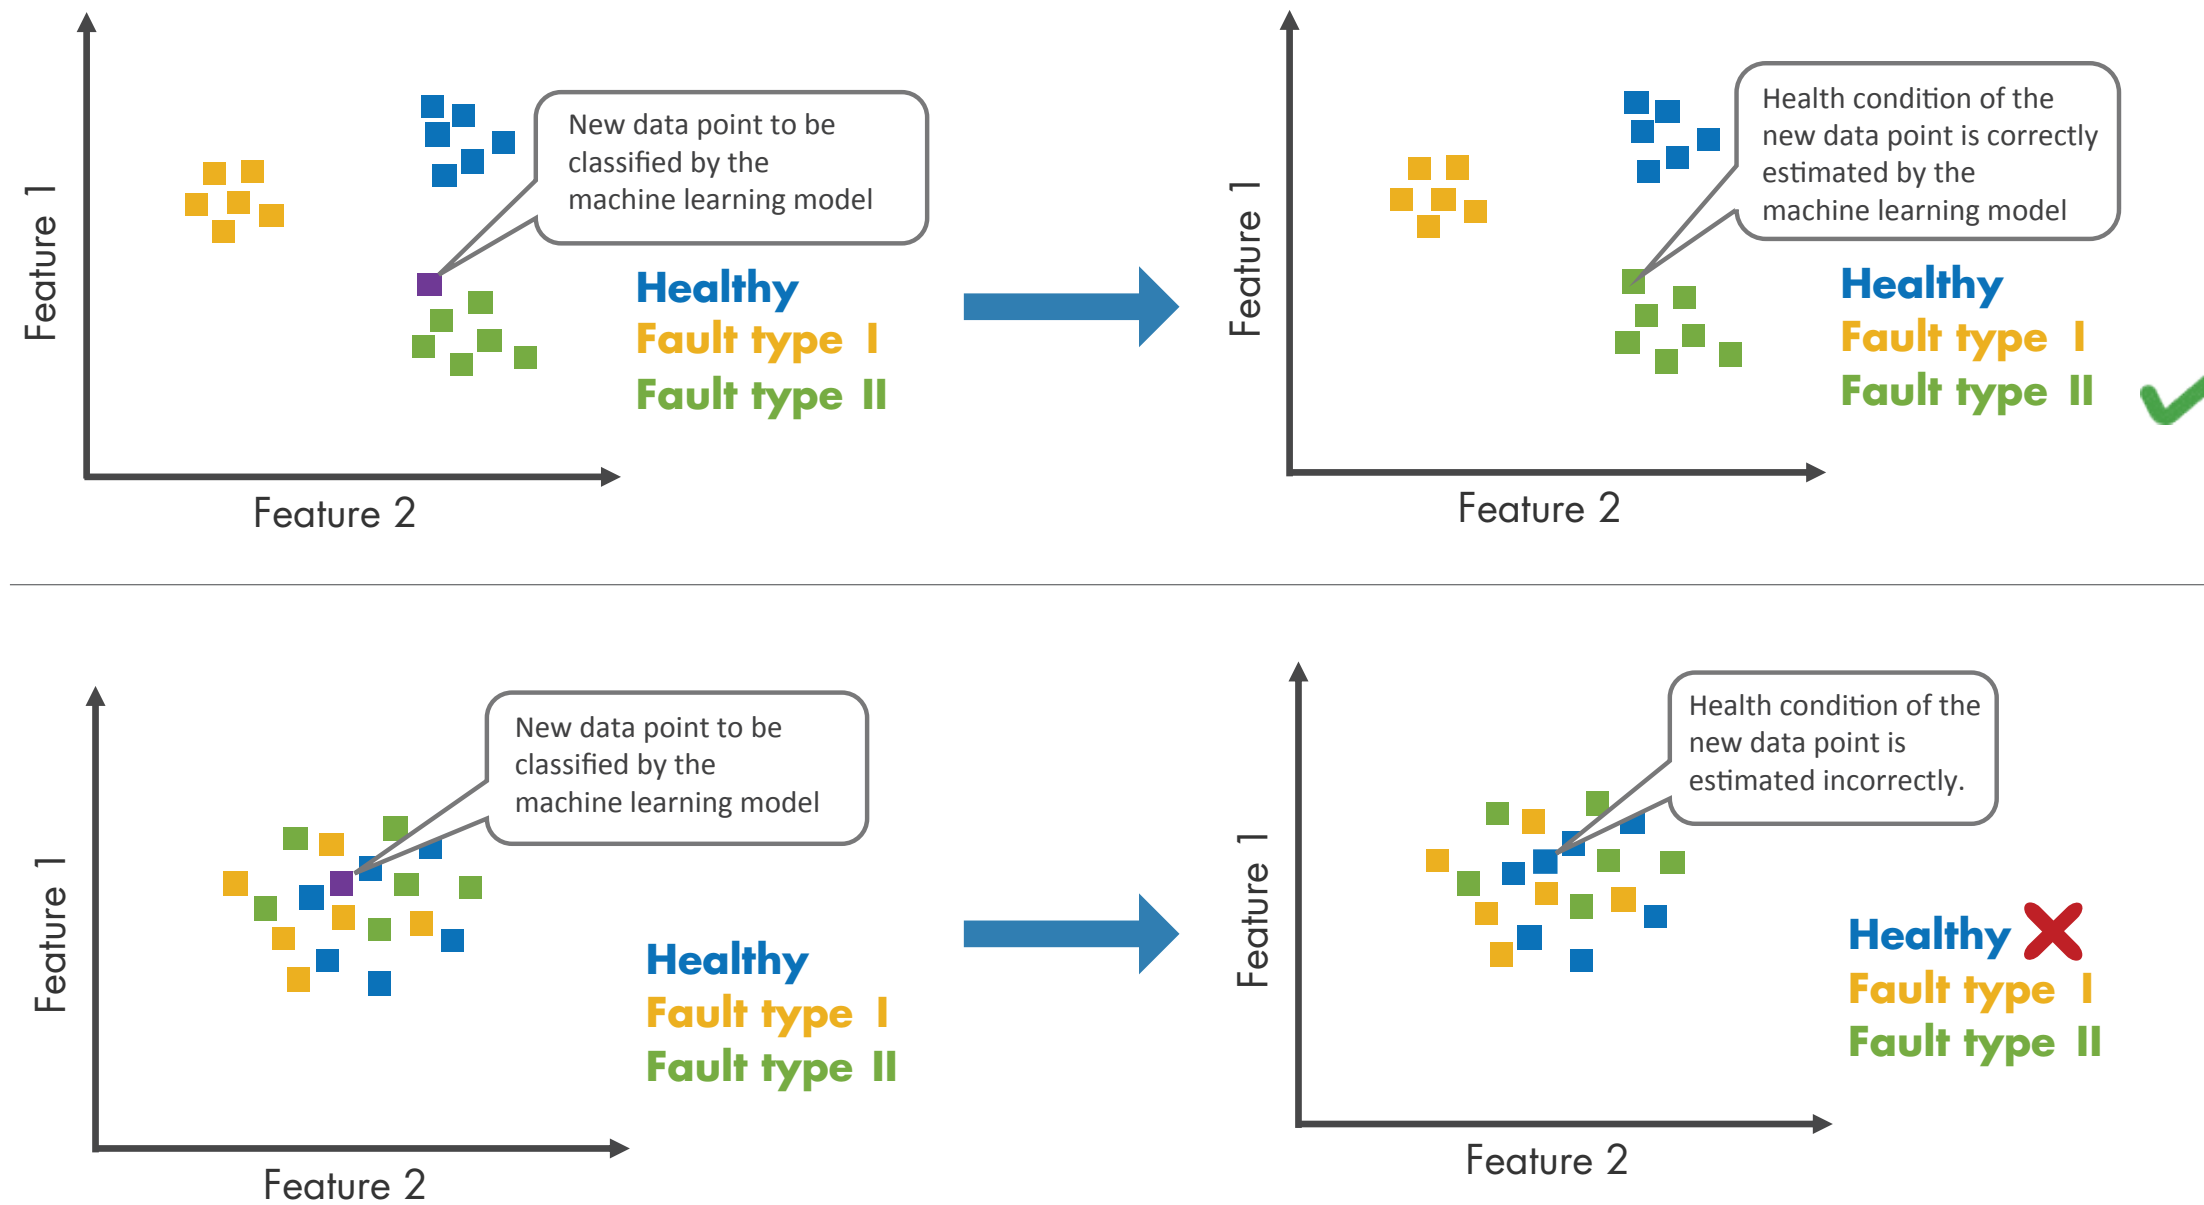
状況インジケータの概要について見たので、状況インジケータを識別する、特徴抽出の手順について見ていきましょう。予知保全アルゴリズムの設計は、異なる動作条件と故障状態で機械からデータを収集することから始まります。そして、生データは前処理され、状況インジケータを抽出できる形式に変更されます。特徴抽出とは、正常な動作と様々な故障タイプを明確に区別できる特徴を探す作業です。これらの特徴が状況インジケータになります。

抽出された特徴を使用して、故障分類と残存耐用期間の推定のため機械学習モデルを学習させることができます。アルゴリズムを展開して、機械の監視とメンテナンスのためシステムに統合することができます。



よい特徴の概要とそれが重要である理由


有益な特徴を特定すれば、それを機械学習モデルの学習に使用することができます。選択された一連の特徴が区別しやすいものであれば、新しいデータを機械からモデルに入力したときに、モデルは機械の現在の状態を正しく推定することができます。




例: Triplex ポンプ

この例では Triplex ポンプを使用して、ワークフローを説明します。ポンプにあるモーターがクランク軸を回転させ、それがプランジャーを駆動します。流体がインレットから吸入されたあと、アウトレットから放出され、水圧がセンサーにより計測されます。このようなポンプで起こる故障には次のようなものが含まれます。

- シール漏洩
- インレット詰まり
- ベアリング磨耗




データの取得



この水圧データには、正常動作での定常状態、3 つすべての故障タイプ、およびそれらすべての組み合わせにおける 1 秒間の計測が含まれます。


- 正常
- インレット詰まり
- ベアリング磨耗
- シール漏洩
- インレット詰まり、ベアリング磨耗
- シール漏洩、ベアリング磨耗
- シール漏洩、インレット詰まり

Raw data

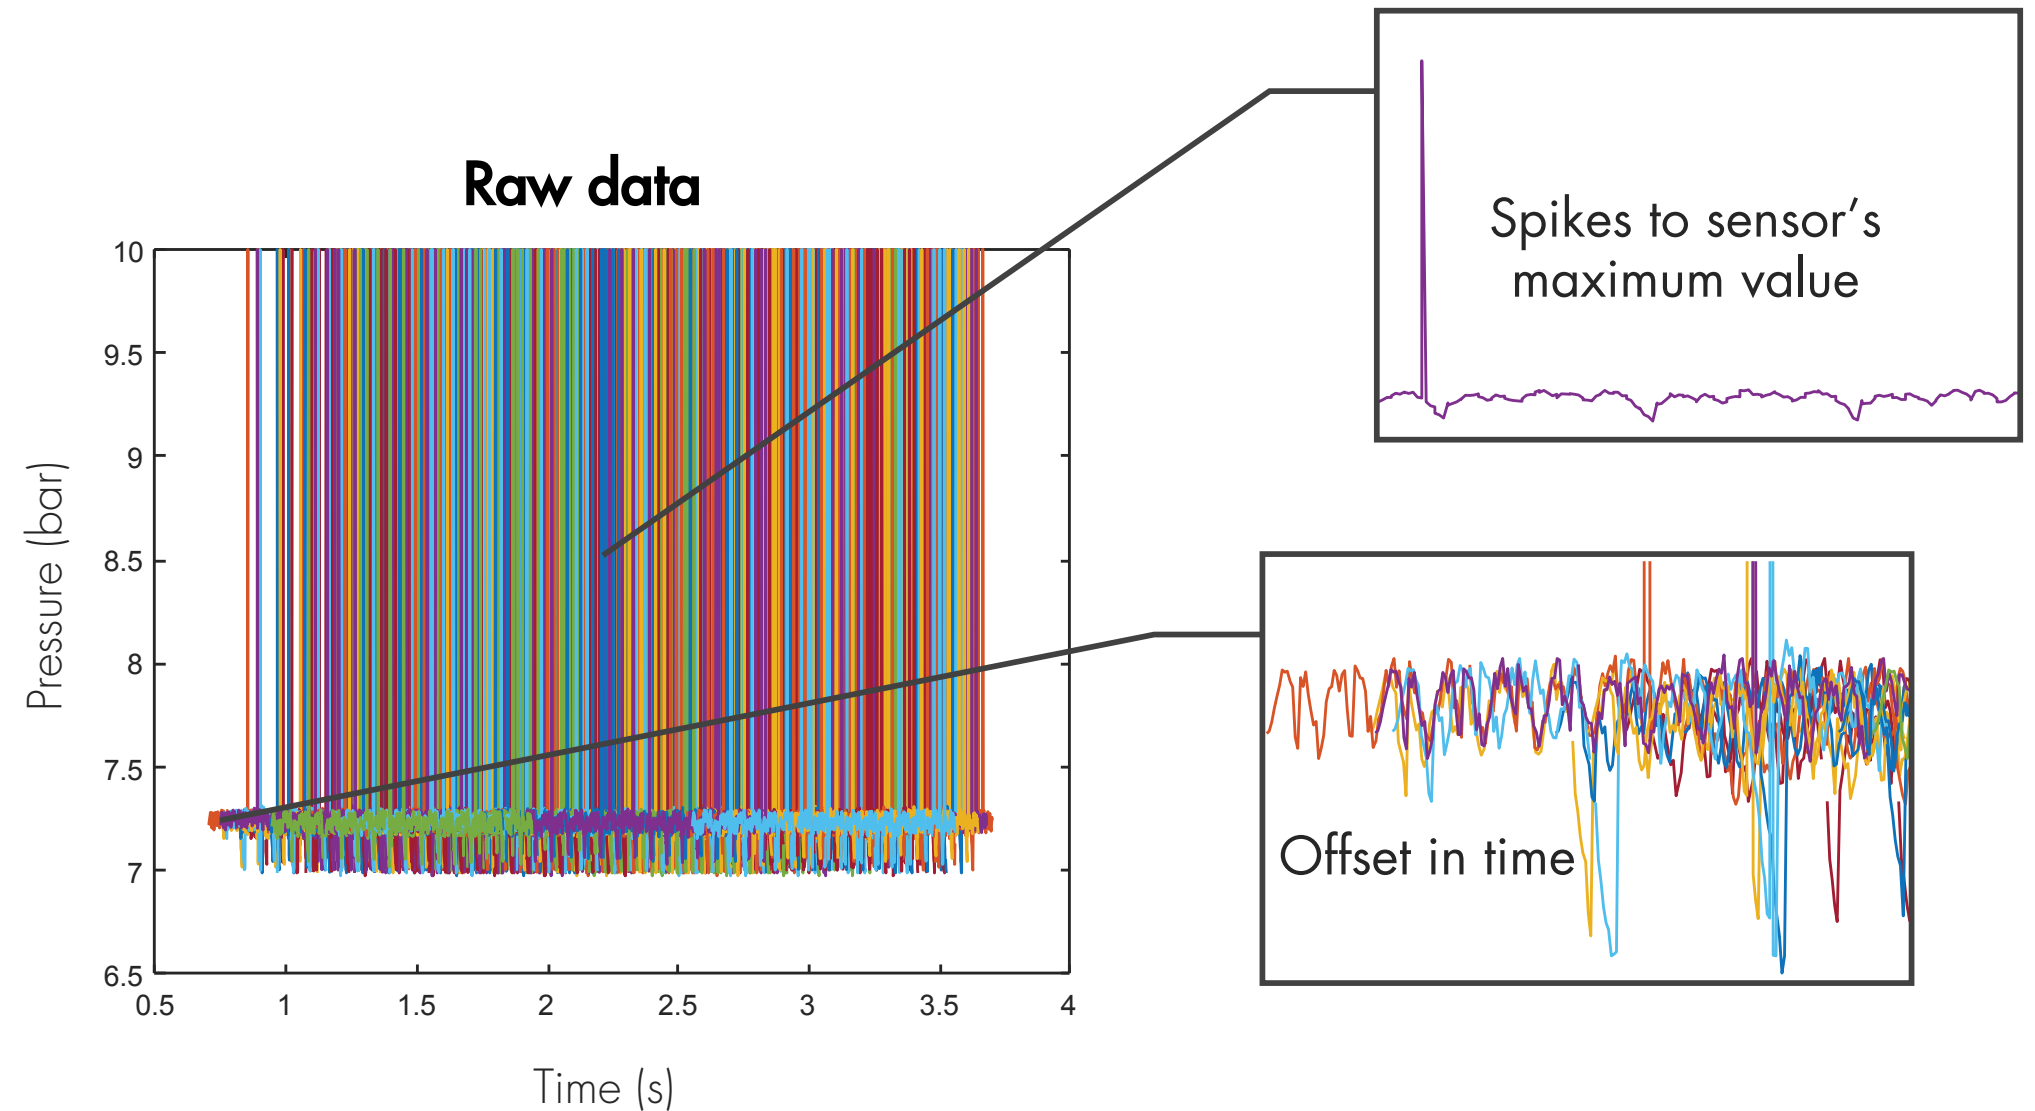


Triplex ポンプから収集された水圧データのプロット。

データの前処理




状況インジケータ抽出のため、使用できる形式に変更する必要があります。生データにはノイズが含まれ、センサーの最大値に達するスパイクがあります。また計測時間の長さが一緒でも、時間のずれがあります。



データの事前処理 - 続き

MATLAB にはデータを滑らかにしてノイズを除去し、信号データに対し他の前処理の手法を実行する関数があります。








前処理されたデータには、すべての正常または故障の条件が含まれます。異なる故障タイプとその組み合わせを調べるため、それらを個別にプロットできます。これらのプロットで最初に気が付くのが、時間領域での水圧信号の周期的挙動です。次に、各サイクルで起きていることをより明確に見るため、より短い時間周期でのプロットを次のページで見てください。



データの前処理 - 続き

これらのプロットにより、異なる故障タイプの水圧信号をより詳細に見ることができます。ポンプの悪化に伴う水圧データの変化が、濃い青から赤に変化する色に反映され、増大する故障の深刻度を表しています。ここでの質問はこうです。正常な動作である黒の線から、他のデータを各プロットで区別できますか?そして、それぞれの色の線の間にある固有の違いを特定できますか?「シール漏洩、インレット詰まり」と「インレット詰まり」の故障において、水圧データが非常に似ていることに気が付くと思います。

それでは、時間領域の特徴をいくつか見て、状況インジケータを特定して故障タイプを区別しましょう。





状況インジケータを識別する 時間領域の特徴を使用

試行錯誤をして、次の一般的な時間領域の特徴がどのように振る舞うか見ていきます。[平均](#)、[分散](#)、[歪度](#)、および[尖度](#)。


これらの状況インジケータが故障タイプを区別できるか理解する方法の一つは、箱ひげ図を使用して調査することです。最初に平均のような単一の特徴を、正常条件とインレット詰まりのためプロットします。

データに重なりがないことが見て取れます。これはこれらのデータのグループ間で違いがあることを意味します。水圧データの平均を使用することで、インレット詰まりと正常条件を簡単に区別することができます。







状況インジケータを識別する時間領域の特徴を使用 - 続き

他の故障タイプのデータセットも追加すれば、事情は変わります。いくつかは重なるので、すべての故障タイプの間を区別することはできません。この重なりがあるため、平均のみでは故障タイプを分離するのに十分ではありません。



状況インジケータを識別する時間領域の特徴を使用 - 続き

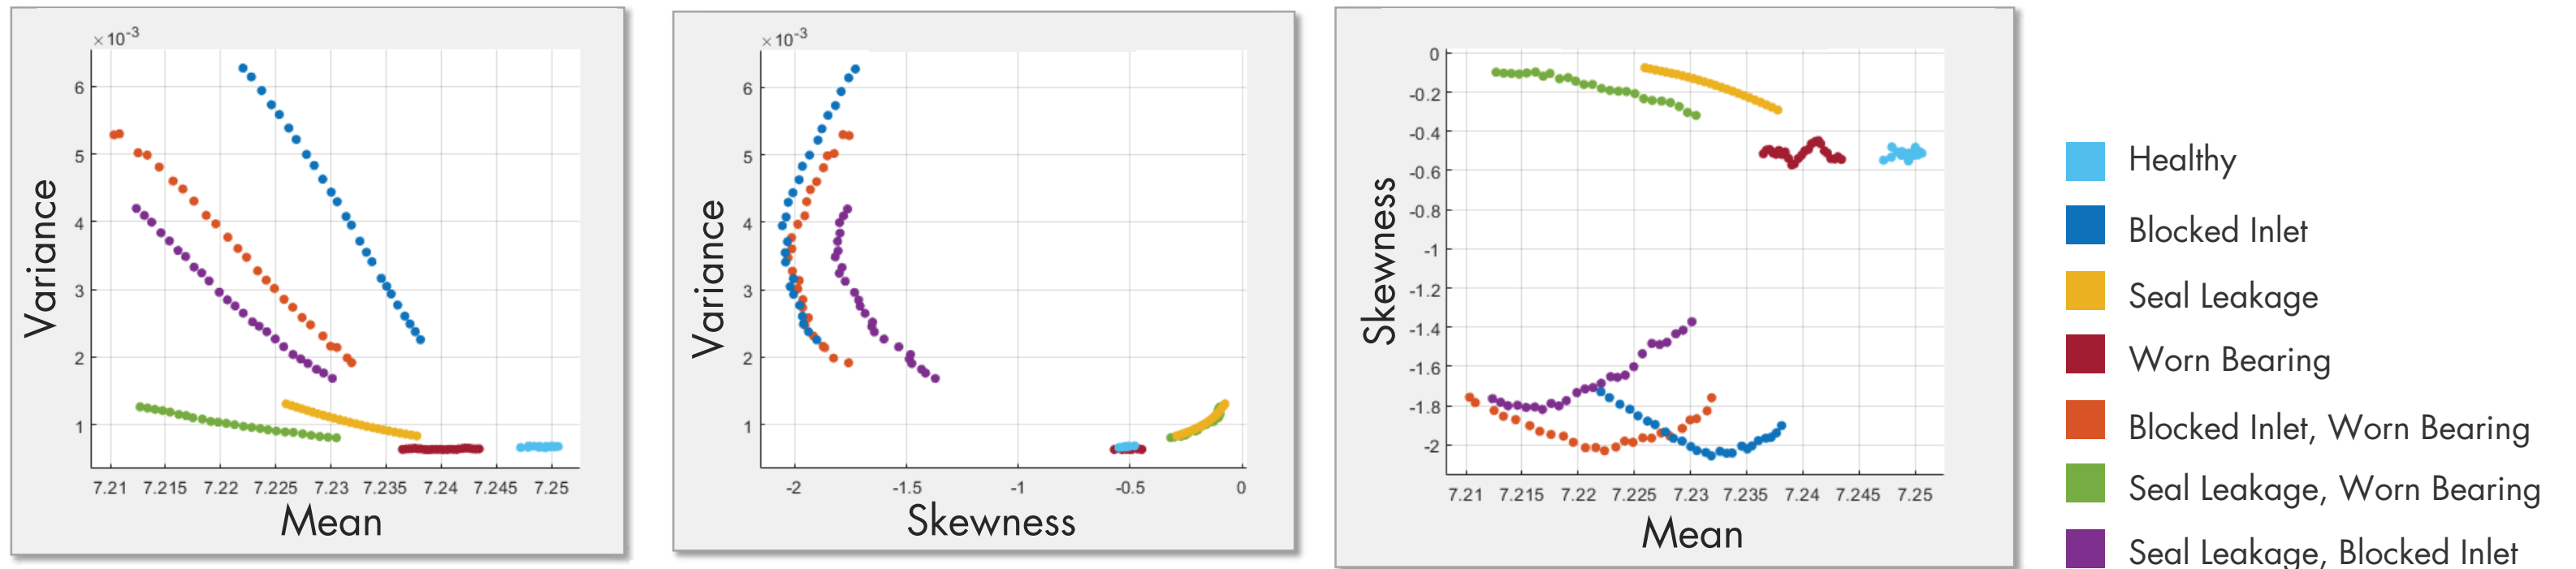
他の特徴を試しても、同じ結論になります。単一の状況インジケータでは、特に複数の故障がある場合には、故障の挙動を分類するのに十分ではありません。



- Blocked Inlet
- Blocked Inlet, Worn Bearing
- Seal Leakage
- Seal Leakage, Blocked Inlet
- Seal Leakage, Worn Bearing
- Healthy
- Worn Bearing

状況インジケータを識別する時間領域の特徴を使用 - 続き

以下の図は、平均、分散、および歪度の特徴を組み合わせた散布図です。分散対平均のプロットが異なる故障タイプを最も区別していることに気が付くと思います。



異なった故障を分離するには2つの状況インジケータが1つより良いことがすぐに分かります。違ったペアの特徴を試して、故障の分類に適したものを調べることができます。

状況インジケータを識別する時間領域の特徴を使用 - 続き

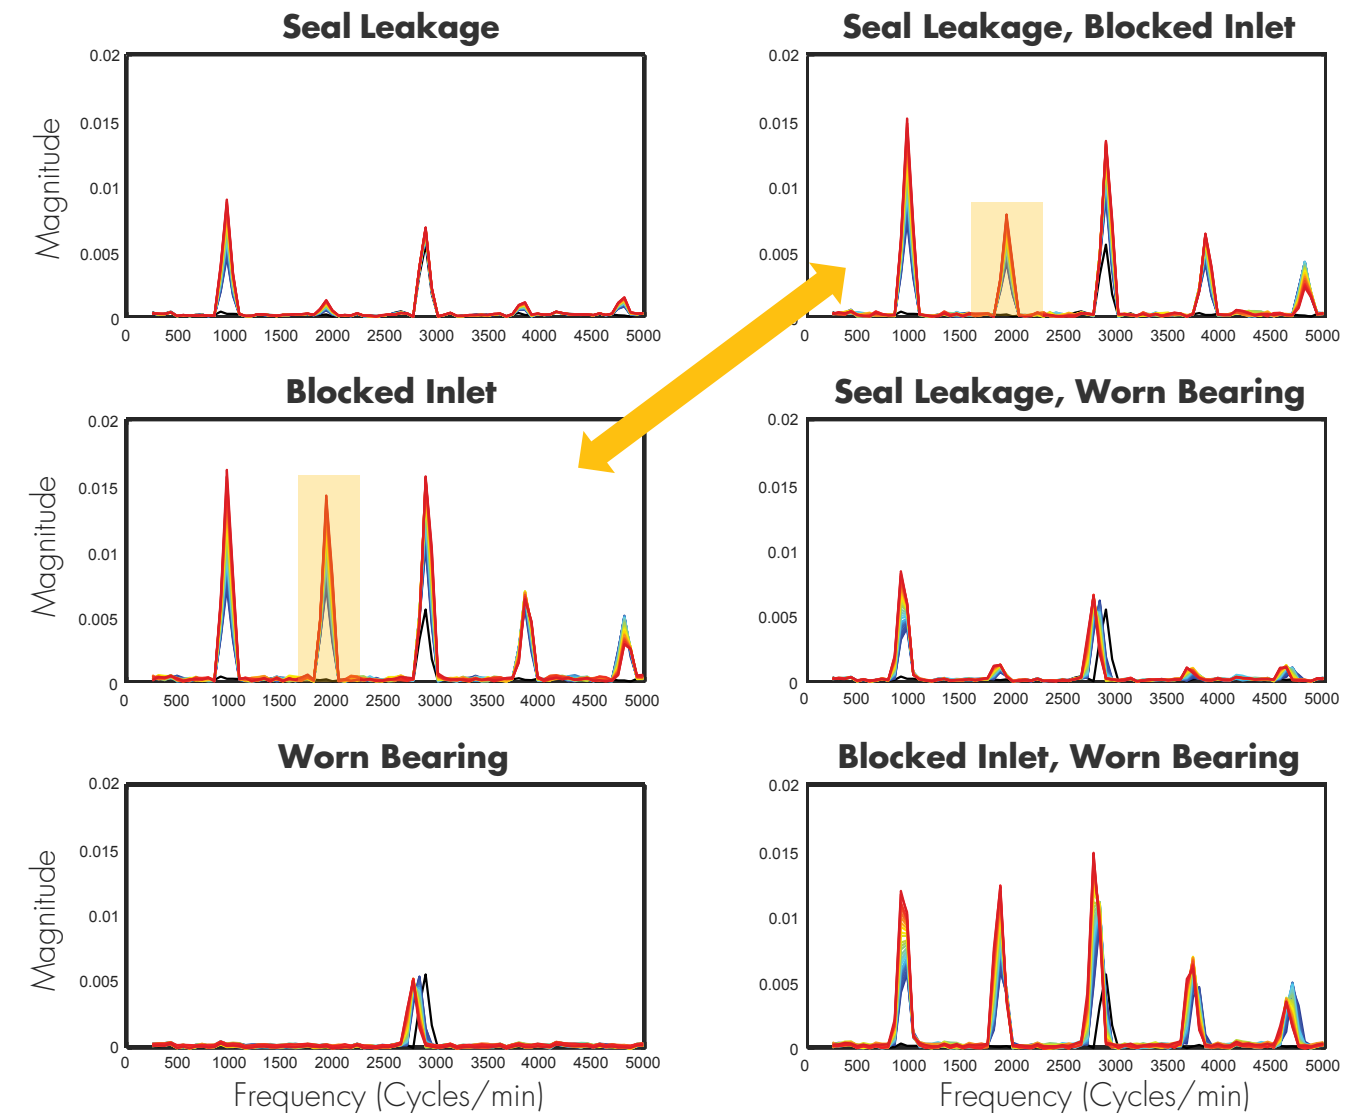
周波数領域の解析は、回転コンポーネントを持つ機械から取得された周期的データの解析において重要です。周波数領域でデータを解析することで追加の特徴を抽出できるか見ていきましょう。

これらのプロットがそれぞれを区別するのは、ピークとピーク周波数です。そのため、これらは状況インジケータとして機能します。時間領域の特徴では、データセットが似ているため、「シール漏洩、インレット詰まり」と「インレット詰まり」を区別することが困難でした。周波数領域でデータを見ることで、ハイライトされた周波数域でのピーク値により、2つの故障の分離に成功するのを見ることができます。

MATLAB では、`fft` 関数を使用して、信号の高速フーリエ変換を算出し、周波数領域でそれを解析することができます。そして、`findpeaks` を使用してピークとピーク周波数を FFT 信号から抽出することができます。

要約すると、この例で機械学習モデルの学習に使用すべき特徴は次のようになります。


- **時間領域の特徴:** 平均、分散、歪度、および尖度。
- **周波数領域の特徴:** ピークとピーク周波数



状況インジケータを識別する時間領域の特徴を使用 - 続き

周波数領域を選択したあと、時間領域で行ったような解析を試します。以下のプロットは、それぞれに関する2番目と5番目のピークを表示しています。

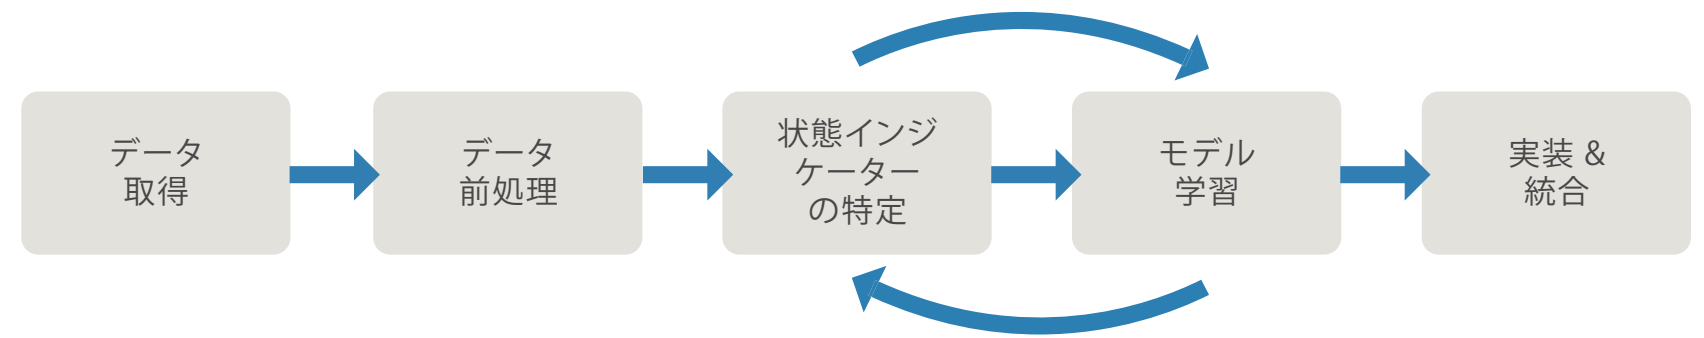
これらの特徴は効果的に、黄色でハイライトされた異なるグループを分離しています。これは、選択した特徴が区別しやすいもので、機械学習モデルの学習の良い候補であることを意味しています。



これらの特徴を調査しているときは、異なった一群を探しているだけでなく、それらがより離れていることが望ましいことに注意してください。これは学習済みモデルでの、新しいデータの点の識別をより簡単にします。

前のページでは各故障のピークを、故障は色つきで正常条件は黒で見ました。「ベアリング磨耗」のプロットには、ベアリング磨耗と正常条件のための3番目のピークしか含まれていなかったことに気が付くと思います。これが、これらの条件が2番目と5番目のピークを表現するプロットに現れていない理由です。これは、効果的に異なるグループを分離するために、複数の特徴が必要である別の理由です。

モデルの学習

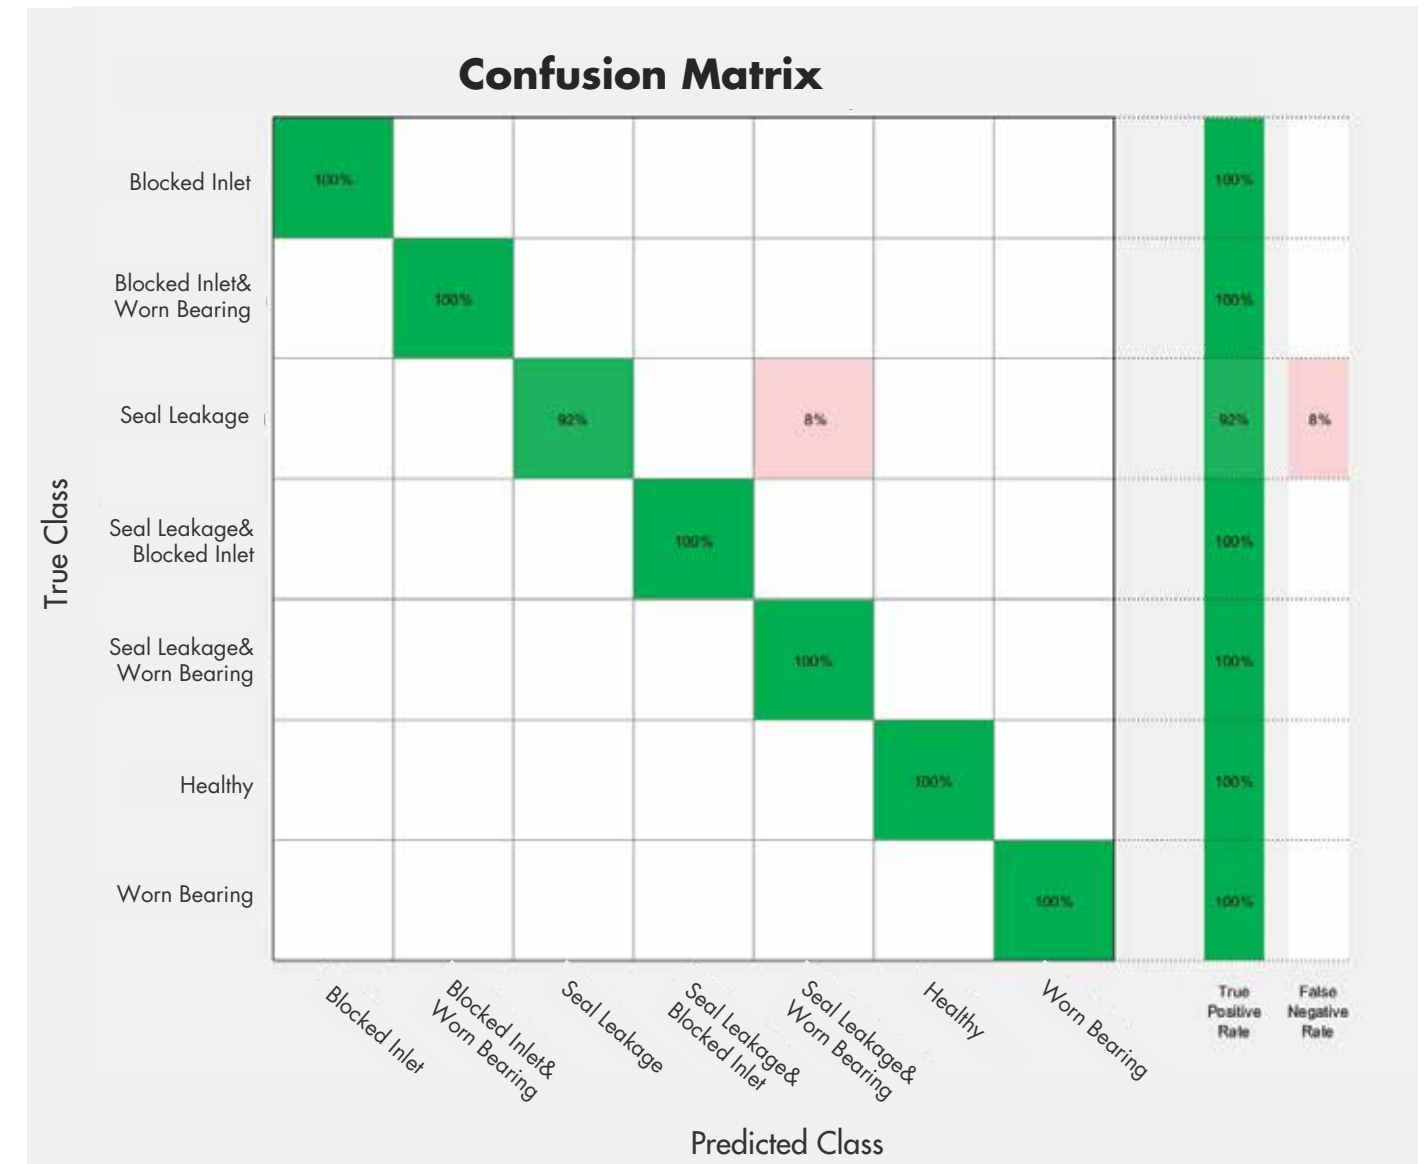


状況インジケータの抽出後、抽出した特徴で機械学習モデルの学習を行い、混合行列で学習したモデルの精度を確認することができます。右の混合行列は、抽出した特徴で学習した最も良い分類器の結果を表しています。MATLAB の [分類学習器アプリ](#) は、データセットに最も良い分類器をすばやく見つけるのに役立ちます。

プロットでは真陽性比率を緑で偽陰性比率を赤で表示しています。

機械学習モデルの精度に満足したら、予知保全アルゴリズムを展開し、システムに統合する手順に進むことができます。そうでなければ、ワークフローチャートの矢印でハイライトされているように、予知保全ワークフローの特徴抽出の手順に戻り、異なる特徴の組み合わせでの機械学習モデルの学習を試すことになります。

いくつかの特徴があれば機械学習モデルの学習に十分か、疑問に思うかもしれません。残念なことに、魔法の数字はありません。機械学習モデルは、故障タイプを効果的に区別することができる、高次元の特徴から恩恵を受けることを覚えておいてください。



関連情報

見る

[予知保全 Tech Talks - ビデオシリーズ](#)

[MATLAB および Simulink での予知保全 \(35:54\) - ビデオ](#)

[Diagnostic Feature Designer アプリを使用した特徴抽出 \(4:45\) - ビデオ](#)

読む

[予知保全で直面しやすい 4 つの課題とその対処法 - ホワイトペーパー](#)


調べる

[MATLAB による予知保全 - コードサンプル](#)

[Predictive Maintenance Toolbox - 概要](#)

» [Predictive Maintenance Toolbox を試す](#)

パート 3: 残存耐用時間の推定




残存耐用時間とは

予知保全の目標の 1 つは、システムの残存耐用時間 (RUL) を推定することです。RUL は、システムの現在の状態から故障までの時間です。システムに応じて、時間が、日数、フライト数、サイクル数、または他の数量の観点で示されます。

プロットには、時間が経つにつれ機械が劣化していく過程が示されます。

この eBook では、RUL の推定に使用される一般的な 3 つのモデル (類似性モデル、生存モデル、および劣化モデル) を取り上げ、類似性モデルを用いた例で RUL のワークフローを確認します。



RUL を推定する 3 つの一般的な方法


RUL の推定には、類似性モデル、生存モデル、および劣化モデルという 3 つの一般的なモデルが使われます。どのモデルを使用すべきかは、お持ちの情報の量によって変わります。

故障に至るまで実行された完全な履歴データがなく、故障時のみのデータを保持している場合は、**生存モデル**を使用します。

正常な状態から故障までの間でデータがあり、超えてはいけない安全のためのしきい値が分かっている場合は、**劣化モデル**を使用します。

保持するデータが、正常な状態から故障までのシステムの劣化全体を網羅している場合は、**類似性モデル**を使用します。

RUL ESTIMATOR MODELS



より詳細な情報は、予知保全で用いられる **RUL 推定器モデル** を参照してください。

次の航空機エンジンの例で、推定器モデルの動作方法について解説します。

RUL 推定器モデルの動作原理：生存モデル


RUL ESTIMATOR MODELS

SURVIVAL MODEL

Use when you have failure data from similar machines

DEGRADATION MODEL

SIMILARITY MODEL



● Engine in operation

●● Historical fleet data

● Engine failures

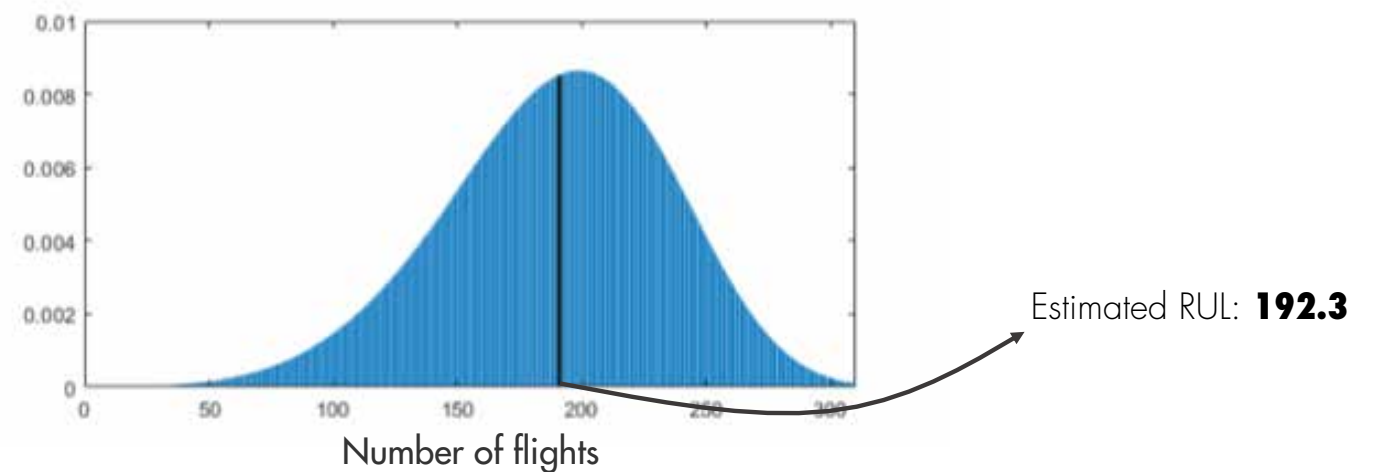
この例では、パーツの修理または交換が必要になるまでに、エンジンが何回フライトを実施できるかを特定することを目標としています。

プロットの黄色の線は、これまで 20 回のフライトを行ったエンジンを表しています。青色の線は、同じタイプのエンジンを持つ航空機からのデータを表しています。赤色のマークがエンジンの故障時を示しています。

航空機からの完全な履歴データがない場合でも、故障データがあれば生存モデルを用いて RUL を推定することができます。

一定回数のサイクル (フライト数) の後に、いくつかのエンジンが故障したかを調べることができます。また、エンジンのそれまでのフライト数も分かります。生存モデルでは、このデータの確率分布を使用して残存耐用時間を推定します。

Probability density function for the RUL estimation after 20 flights



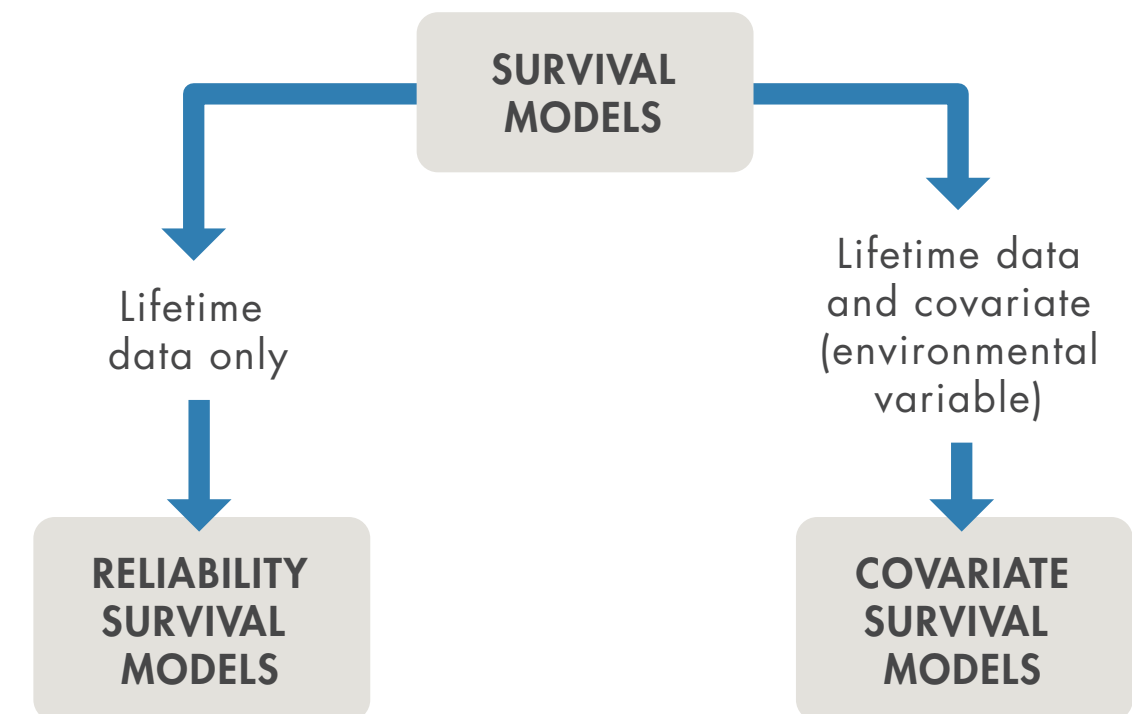
RUL 推定器モデルの動作原理

MATLAB での生存モデル

生存解析は、イベント発生までの時間のデータをモデル化する統計的手法です。故障に至るまで実行された完全な履歴データがなく、次のデータのみがある場合に便利です。

類似したコンポーネントの生存期間に関するデータのみ たとえば、集合の中のそれぞれのエンジンが何マイル走るとメンテナンスが必要かということが分かっているとします。この場合は、**reliabilitySurvivalModel** という MATLAB® モデルを使用します。類似するコンポーネントを持つ航空機における故障時の履歴情報がある場合、このモデルは故障時の確率分布を推定します。テストコンポーネントの RUL を推定するために、分布が使用されます。

生存期間、および RUL と相関するその他の変数データ (共変量) の両方 共変量には、コンポーネント プロバイダー、コンポーネントが使用されている枠組み、または生産バッチなどの情報が含まれます。この場合は、**covariateSurvivalModel** という MATLAB モデルを使用します。このモデルは、生存期間と共変量を用いてテストコンポーネントの生存確率を算出する比例ハザード生存モデルです。



RUL 推定器モデルの動作原理 劣化モデル


RUL ESTIMATOR MODELS

SURVIVAL MODEL

DEGRADATION MODEL

SIMILARITY MODEL

Use when you have know a threshold of some condition indicator that indicates failure



たとえば、類似する機械からの故障データが利用できないものの、故障の原因となりうるため超えてはいけない安全のしきい値が分かっている場合があります。この場合、情報を使用して劣化モデルを状態インジケータに当てはめることができます。状態インジケータはエンジンからの過去の情報を使用して、それが将来どのように変化するかを予測します。この方法により、状態インジケータがしきい値を超えるまでに何回のサイクルがあるかを統計的に推定することができます、それが残存耐用時間の予測に役立ちます。

RUL 推定器モデルの動作原理

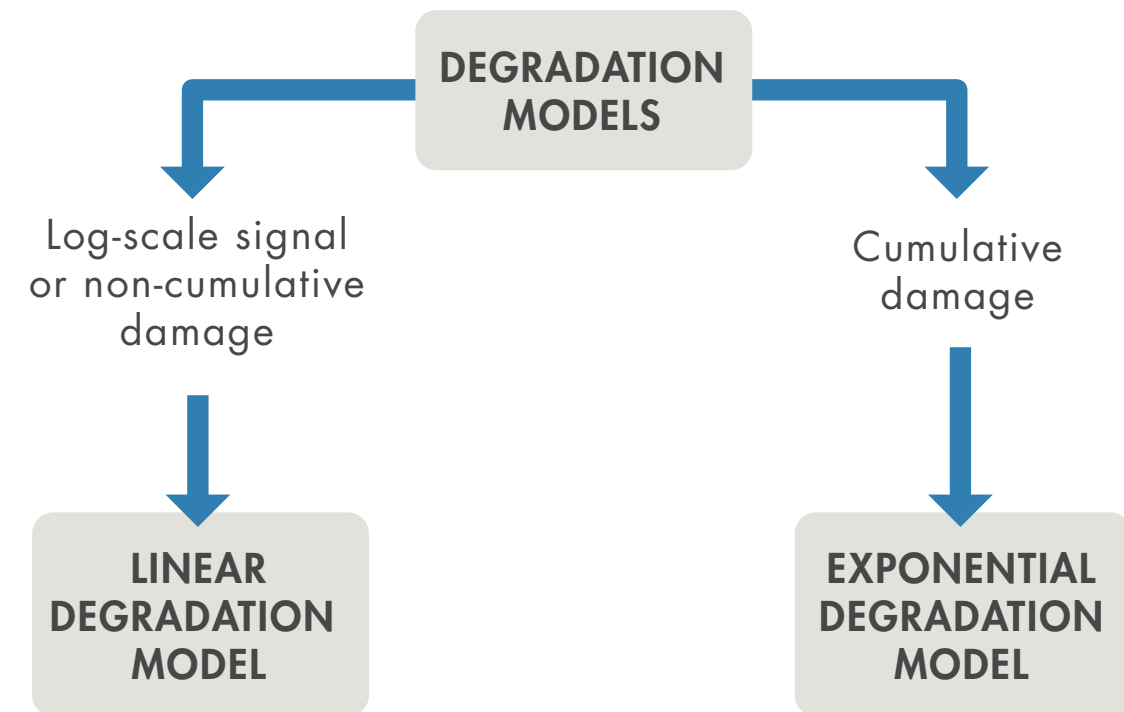
MATLAB の劣化モデル

劣化モデルでは、状態インジケータが事前に設定されたしきい値をいつ超えるかを予測することにより、RUL を推定します。これらのモデルは、故障を示す状態インジケータの値が分かっている場合に便利です。Predictive Maintenance Toolbox™ で利用できる 2 つの劣化モデルは次のとおりです。

線形劣化モデル (linearDegradationModel) は、劣化動作をオフセット項を持つ線形確率プロセスとして示します。線形劣化モデルは、システムに蓄積的な劣化がない場合に便利です。

指数劣化モデル (exponentialDegradationModel) は、劣化動作をオフセット項を持つ指数確率プロセスとして示します。指数劣化モデルは、テストコンポーネントに蓄積的な劣化がある場合に便利です。

劣化モデルは単一の状態インジケータで機能しますが、主成分分析やその他の合成手法を用いて、1 つ以上の状態インジケータからの情報を統合する融合状態インジケータを生成することができます。



RUL 推定器モデルの動作原理

類似性モデル


RUL ESTIMATOR MODELS

SURVIVAL MODEL

DEGRADATION MODEL

SIMILARITY MODEL

Use when you have run-to-failure histories from similar machines



類似性モデルは、故障に至るまで実行したデータ (正常な状態から劣化および故障までの、同じタイプのエンジンを持つ航空機からの完全な履歴データ) がある場合に便利です。

RUL 推定器モデルの動作原理

MATLAB での類似性モデル


Predictive Maintenance Toolbox には、次の 3 種類の類似性モデルが含まれています。

ハッシュ特徴類似性モデル (`hashSimilarityModel`) は、集合の中の各メンバーからの劣化履歴データを、平均値、最大値、または最小値などの固定サイズの凝縮された情報に変換します。

ペアワイズ類似性モデル (`pairwiseSimilarityModel`) では、劣化の過程がテストコンポーネントと最も相関しているコンポーネントを見つけ出します。

残差類似性モデル (`residualSimilarityModel`) では、以前のデータを ARMA モデルまたは使用時に線形か指数になるモデルを当てはめます。その後、集合モデルから予測されたデータと、テストコンポーネントからのデータの間に残差を算出します。詳細は、「[類似度ベースの残存耐用期間推定](#)」をご覧ください。

次のセクションでは、類似性モデルの詳細を確認しながら、RUL 予測の実行方法について解説します。





RUL 推定ワークフロー 類似性モデルの使用

データの取得


類似性モデルは、便利な RUL 推定手法です。このモデルの使用方法を具体例で確認し、RUL 予測の実行についての理解を深めましょう。

予知保全モデルを開発するために、まず、データを取得します。この例では、[NASA のデータリポジトリ](#)から一般にも利用可能な Prognostics and Health Management (故障予測と健全性管理、PHM) 課題データセットを使用します。このデータには、故障に至るまでの 218 のエンジンのデータが含まれています。それぞれのエンジンのデータセットには、21 のセンサーからの計測値が含まれています。エンジンのさまざまな箇所に配置されたセンサーから、燃料フロー、温度、および圧力などの計測値を集めて制御システムに送り、エンジンの状態を監視しています。このプロットは、1 つのセンサーの計測値が 218 のすべてのエンジンでどのように変化しているかを示しています。

プロットでは、X 軸がサイクル数 (フライト)、Y 軸が各フライトでのセンサーの平均値を表しています。各エンジンの正常な状態から故障までが示されています。

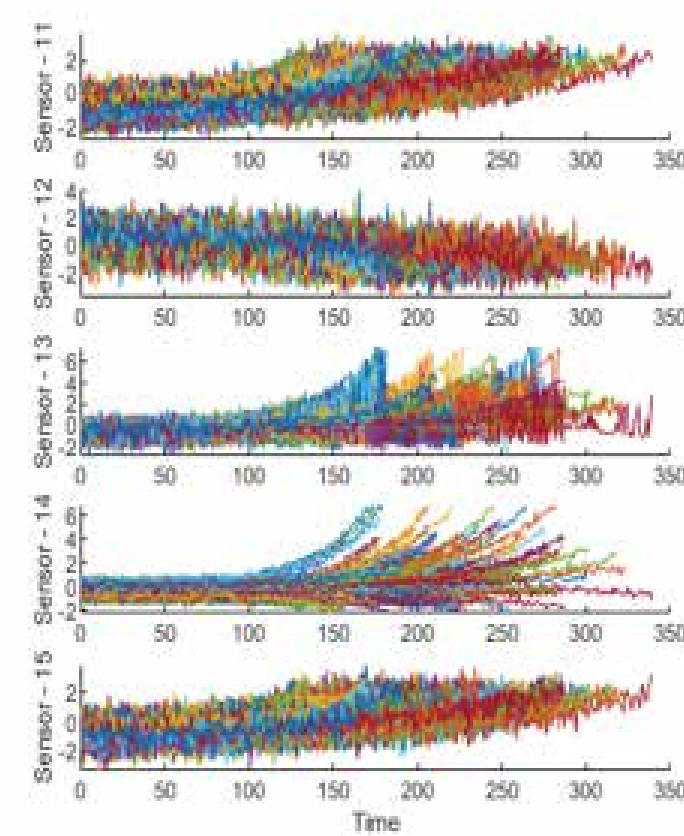




RUL 推定ワークフロー 類似性モデルの使用 続き



データの前処理および状態インジケータの特定

前のページでは、センサー 4 からのデータを示しましたが、データセットには他の 20 のセンサーからのデータも含まれています。他のセンサーの結果を詳しく見ると、いくつかの計測値には、故障に向う明確なトレンドがないことが分かります (センサー 1、5、6、および 10 など)。そのため、これらは類似性モデルの学習に有益な特徴の選択には役立ちません。



RUL 推定ワークフロー：類似性モデルの使用 続き

データの前処理および状態インジケータの特定

すべてのセンサーからの計測値を使用する代わりに、トレンドを最もよく示す 3 つのデータセット (正常状態と故障の間でプロファイルに大きな変化があるもの) を特定します。センサー 2、11、および 15 が、劣化プロファイルを作成するために使用する組み合わせとして適しています。


劣化プロファイルは、集合の中の各機械 (各コンポーネント) についての 1 つ以上の状態インジケータが示す、機械の正常状態から故障状態への進展度です。

前処理の手順で、トレンドを最もよく示すセンサー (センサー 2、11、および 15) のみを選択し、それらを組み合わせて状態インジケータ


を算出することで、データを削減します。

状態インジケータを選択して適用する方法については、「[予知保全: MATLAB で状態インジケータを抽出](#)」で詳細をご確認ください。

現在のエンジン (黄色) の残存耐用時間を推定するには、センサー 2、11、および 15 を使用して、航空機の劣化プロファイルを示す状態インジケータを算出します。右のグラフでは、エンジンが現時点で 60 回のフライトで使われたということと、赤の時点で類似の航空機エンジンが故障したことが示されています。



Combine the most trendable sensors to compute condition indicators



RUL 推定ワークフロー



類似性モデルの使用 続き

類似性モデルの学習

データを2つのグループに分け、大部分を類似性モデルの学習に使用し、残りを学習済みモデルのテストに用います。既知のRULを使用して学習済みモデルの精度を評価します。

類似性モデルは、現在のサイクルまでのエンジンに最も近いエンジンプロファイルを見つけることで機能します。最も類似したエンジンの故障時点の情報が履歴データにあるため、現在のエンジンの予想される故障時期が分かります。下のプロットに示されているように、このデータを確率分布に当てはめることができます。







この分布の中央値が、エンジンの残存耐用時間の推定になり、これと実際のRULを比較して精度を計測することができます。



RUL 推定ワークフロー：類似性モデルの使用 続き

類似性モデルの学習

RUL を算出するたびに、類似性モデルが最も近いエンジンの過程 (緑色で示されます) を探し出し、確率分布プロットを用いて RUL を算出します (右)。下のプロットでは、エンジンプロファイルと次の 3 つのサイクルでの確率分布が示されています：25、65、および 115。



RUL 推定ワークフロー：類似性モデルの使用 続き


類似性モデルの学習

確率分布プロットでは、オレンジ色の線が予測された RUL を表し、黒色の線が実際の RUL を表しています。

エンジンが 25 サイクル (フライト) 目にあるときは、モデルが学習するデータが少ないため、予測は非常に大きな分布となり、実際の値より 40 サイクル外れています。

時間が経過し、モデルで使用できるデータが増えるにつれて、予測された RUL が実際の RUL に近づいていることが分かります。

現在のサイクル 25




サイクル 65 と 115 で見られるように、モデルがエンジンから新しいデータを取得するにつれ、類似性モデルは、より多くのデータから学習するようになります。その結果、時間の経過とともに、予測精度が改善します。

サイクル 115 の RUL 推定を用いると、エンジンの RUL に関する非常に正確な予測ができ、最良の時期にメンテナンスを予定することができるようになります。

データが増えるにつれ、RUL 予測がより正確になり、分布がより集中します。

現在のサイクル 115



関連情報

予知保全ワークフロー、サンプル、およびツールに関するさらに詳しい情報については、以下をご覧ください。

見る

[Predictive Maintenance Toolbox とは \(2:06\) - ビデオ](#)

[予知保全 Tech Talks - ビデオシリーズ](#)

[MATLAB および Simulink での予知保全 \(35:54\) - ビデオ](#)

[Diagnostic Feature Designer アプリを使用した特徴抽出 \(4:45\) - ビデオ](#)

読む

[予知保全で直面しやすい4つの課題とその対処法 - ホワイトペーパー](#)

[予知保全のための MATLAB および Simulink - 概要](#)

[MATLAB での予知保全の例 - コードサンプル](#)