

# AI による故障予測 ~物理モデルによる異常データ生成~

MathWorks Japan

井上 道雄 Michio INOUE 王 暁星 Xiaoxing WANG

## 1. はじめに

AI を活用した「予知保全 (Predictive Maintenance)」の取り組みが注目を浴びている。予知保全とは機器に取り付けられた各種センサーから得られる情報から、機器の故障時期を予測し適切なタイミングでメンテナンス実施を目指すものである。過度なメンテナンスを避けられることによるコスト低減はもちろん、突発的な故障を減らすことで稼働率や安全性の向上なども期待される。IoT やAI の普及に伴って工作機械や生産設備など様々なところで予知保全のニーズは今後更に高まることが予想される。

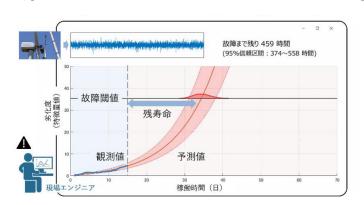


図1 機器に取り付けたセンサーデータから機器の残寿命を予測する例

また AI 関連の技術はここ数年で急速に発展し最近では AutoML[1] など一部の過程を自動化する技術も提供されるなど、AI 利用に対するハードルは下がってきている。その一方で、アルゴリズム開発に不可欠な"故障"時のデータは不足しているケースも多く、予知保全の実用性には懐疑論も存在する[2]。本稿では予知保全に求められるデータ要素や異常データに対する考え方、そして物理モデルを使ったシミュレーションデータによる代替方法を中心に紹介する。

## 2. 故障予測における課題

予知保全システムを構築する上で技術者が直面しやすい課題 [3] の中でも、本稿で注目するのは"故障データが不足している"点である。故障データを得るために機器を故障させるのは費用面で現実的ではないため、故障データの入手は困難である。さらには故障が発生しないよう頻繁にメンテナンスを行っている場合や、セーフティクリティカルなシステムのために故障を発生させるわけにはいかない場合などでは故障データがそもそも存在しないとの声もよく聞く。

監視対象の機器から取得されたデータをもとに故障を

検知しようとしているにもかかわらず、故障時の データが無い場合はどうすればよいのか。予知保 全は機器の運用データを何らかのアルゴリズムに 入れて機械の耐用年数を予測する「ブラックボッ クス」ソリューションではない。本稿のテーマで ある"適切な量の故障データ"も何を実現するかに よって大きく異なる。まず機能要求とそれを実現 するのに必要なデータについて考えてみる。

## 2.1 予知保全に求める機能と必要となるデータ

どんなデータが必要なのかは目的による。異常が発生していることが分かれば十分なのか、それともどんなアクションを起こすかなどの意思決定に寄与する情報が求められるのか、どのレベルでの"故障予測"を実現するべきなのかは明確にする必要がある。

何らかの異常(普段発生しない状況)が発生しているかどうかの判断であれば、例えば正常運用時のデータだけでもある程度の予測はできるだろう(図2上段)。ただ、故障診断を目的とするならば故障部位や故障モードなどのラベル付きのデータを準備する必要があり、運転条件や運転環境も含



図2 予知保全に求める機能レベル

めて考えるとデータ収集におけるハードルの高さは想像に難くない(図2中段)。またメンテナンスまで残された時間の予測(寿命予測)においては、機器の稼働開始から故障発生までのデータ(寿命データ、Run to Failure データとも呼ばれる)があれば解析の幅も広がるが、こちらも収集は難しい。(図2下段)

いずれにしても部品や機械の微妙な変化を検知しようとするのであれば、機械の振動や音などの精密な計測データが重要であり現象がデータに表れていなければいくら高度な手法も役に立たない。目的を明確にしたうえでデータ収集に取り組むのが最も堅実な方法であるが、以下では故障データが手に入らない場合に試行できる方法を紹介する。

## 2.2 故障データがない≠故障の予兆を示すデータがない

経時劣化する機械について劣化の進行度合いが課題であれば、故障データがないことと故障の兆候を示すデータがないことは同一ではないという考え方もできる。時間軸上で正常データと故障データの間に位置する準正常データ(例えばメンテナンス時のデータ)を考察することで、故障の兆候を発見することが可能となる場合もある。(図 3)

図4は2MW 風力タービンの高速シャフトの振動データ [4] (サンプリング周期約100kHz) を1日あたり6秒間、50日分連続してプロットしたものだが、信号のインパルス性が増加傾向にあることがわかる。50日の期間中に内輪の不具合が発生し、ベアリングの故障の原因となっているが、計測の最後まで待たずとも途中の段階で劣化の傾向が見て取れる好例である。

振動データの標準偏差、尖度、ピークツーピーク値(最大値と最小値の差)など、劣化度合いの定量評価と適切な"故障"もしくは"異常"の定義を行えば、図1に示すよ



図3 正常データと故障データの間のデータの活用

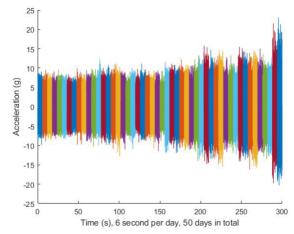


図 4 インパルス特性が増加傾向にある振動データ

うに許容できる劣化度合いを超えるまでの時間、すなわ ち機器の残り寿命を予測することが可能になる。詳細な 解析例については[5]を参照されたい。

## 2.3 データの補完方法

少ない故障データを補完する方法として、加速劣化試験や対象の機器の物理モデルを作成し故障データをシミュレーションで再現する方法がある。後者については次章で詳しく触れるが、前者についても簡単にここで紹介する。

加速劣化試験は機械を過酷な条件下に置くことで劣化速度を上げ製品寿命を検証する試験である。製品の劣化を物理的、化学的に加速することによって短時間に故障を検知することを意図している[6]。人為的に変化させる条件としては温度や湿度などの熱的ストレス、振動や応力などの機械的ストレス、そして電圧、電流などの電気的ストレスが挙げられる。もちろん機器の劣化を完全に再現することはできないが、劣化進展の補助データとして使うことができる。例えば Paris Model など物理的現象に対する数理モデルを使用するアプローチ[7]では、モデルを使用して加速度条件下での計測データを通常運

用時の条件にマッピングさせる。そして上述の劣化モデルのパラメータの事前確率の精度向上に使用し予測精度を上げることが検討されている。また加速要因に依存しない"良い"特徴量の調査に使用するという例もみられる[8]。いずれにしても試験は劣化要因ごとに個別に行われる事が多く、様々な要因が絡みあう現実と同じ劣化が再現できるとは限らない点には留意が必要だ。

# 3. 物理モデルからデジタルツイン

機器の物理的構成要素がどのように互いに影響しあうかを考慮しこれらの相互作用の機能的関係をモデル化する。その際、様々な故障シナリオを想定して物理モデル内にそれらの故障の原因となる劣化のモードを組み込むことで擬似的に故障データを生成する方法である。高度にモデル化されたものはデジタルツインとも呼ばれることもあるが、実際に稼働している設備を仮想空間でモデル化し、リアルタイムの稼働状況や環境情報に応じた動作の評価、そして将来の動作予測、稼働の最適化や故障予測の実現などに期待が高まっている。

例えば Krones 社ではデジタルツインを活用し、デルタロボットを使った飲料パッケージングシステムの大幅なパフォーマンス向上はもちろん、試験期間の短縮、実機との差分解析による故障再現を実現している [9]。 Transocean 社は地下からのガスや原油の噴出を防止する防噴装置の安全性向上にデジタルツインを活用した [10]。

## 3.1 物理モデルの構築と故障データの生成

ここでは MathWorks 社が提供する Simulink® と Simscape<sup>TM</sup> を使用したピストンポンプの物理モデル構築の例を紹介する。

Simulinkでは図 5 右のように Simscape で提供される 物理コンポーネントをブロック図として繋げていくこと で、物理システムを構築する。ピストンポンプの故障の 要因として、モーターの劣化やベアリングの劣化、また パイプラインからの液体の漏れやパイプラインの目詰ま

りなどが考えられるが、各劣化モードは機能要素ブロッ クのパラメータを調整することで故障を模擬する。例え ばトルクのパラメータ値を正常値よりも小さくすること でモーターが劣化した状態を表し、パイプラインと外部 大気が接する断面積の値を大きくすることで液体が外に 漏れている状態を再現する。ベアリングの劣化について はジョイント部分の摩擦抵抗として表現し、パイプライ ンの詰まりについては断面積の値を小さくする。故障が 発生または劣化が進展した際にどんな現象が発生するか を再現するものであり、モデルを実行すれば"自然"と劣 化が進展するというものではなく、劣化の度合いをパラ メータで調整する点には注意されたい。実機の測定デー タをもとにモデルのチューニングを行う場合も多く、物 理モデルを活用する際も実測データの重要性は変わらな いが、実測データがない場合であっても以下のように故 障原因の予測アルゴリズム開発に活かすことができる。

図 6(a) は正常時(黒色)と複数の2つの劣化モードを組み合わせた故障時(灰色)の回転速度を示す。図から故障時のデータは正常時の周期とは異なる振る舞いをしている様子が観察できる。しかし、生データから目視だけで各々の故障形態を判別することは難しい。そこで図6(b) が示すスペクトル解析を行った結果、正常時のスペクトルとの区別は勿論、一部周波数帯で各々の故障形態を区別できる特徴的なピークが求まった。この求められたピーク値とピーク周波数に対して、機械学習を利用することで故障モード判別のアルゴリズムを構築することが可能となる。

このようにセンサーデータを直接利用するのではなく、高いレベルの情報を捉えた「特徴量」を使用することが大事であり、成功の鍵を握る重要なステップである[11]。では振動データを例に故障予測によく用いられる「特徴量」の計算方法について解説しているので参考にして頂きたい。

# EZALVIIV Z

図5 Simulink と Simscape を使用した物理モデルの構築と故障データの生成

### 3.2 物理モデルと現実との乖離

最後に、擬似的に生成した故障時の データの信憑性がどこまであるかの議 論がある。物理モデルを細部まで再現 できれば当然現実により近い故障デー タを生成することが可能となる。物理 モデルはあくまでモデルであり、現実 のデータとは乖離があることを認識し た上で、生成された正常・故障データ がどれだけ直感的に正常・故障時の特

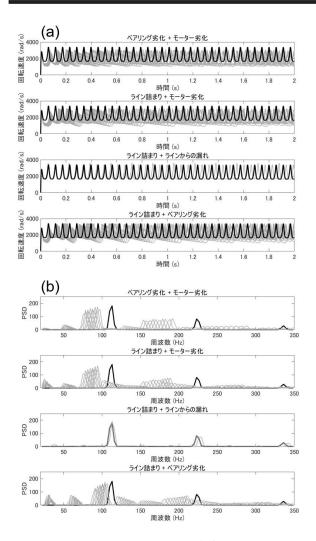


図 6 (a) 擬似的に生成された正常・故障データ、(b) 周波数帯域における正常データと故障データ。異なる故障形態では異なる周波数帯にピークが出現する。

徴を掴んでいるかを把握することが肝要である。故障 データがなく、何もできずに解析を諦めてしまうよりも、 故障時の特徴を定性的なりとも掴んだデータを活用し一 歩前に進み、後から修正を加えていくことが重要だ。

## 4. まとめ

本稿では予知保全を行う際に必要な故障データの種類と、故障データがない場合のアプローチを紹介した。物理法則(例えば電気、機械、油圧等)に基づき機器のモデル化を行うデジタルツインについても触れたが、異常の原因となる要素をモデル内に取り入れることで、故障データを再現することが可能となる。統計解析を中心とする場合においても、変数選択や数理モデル選択に対象機器に対する知見・経験に基づいた判断は必要であるが、物理モデルを使用する方法はその知見の活用をさらに進展させたものと考えることができるだろう。

AI というと機械学習を適用する部分だけが注目を集めがちだが、具体的にどの判断を AI に担わせるのか、そのために必要なデータは何か、そのデータはどこからやってくるのかについても、改めて検討の余地があるように考える。そして最終的にアルゴリズムはどう実装するのかという部分も含め、システム全体を考えた開発が重要だ。これらの要求に対していわゆるドメイン知識が果たす役割は大きい。 MATLAB® はデータの前処理からアルゴリズムの開発だけでなく、データの作成、さらにはシステムへの展開までの全体のワークフローをカバーするプラットフォームとして活用することができる。データサイエンスとドメイン知識との橋渡し役となるプラットフォームを組織的に利用することにより、より一層資産共有及び再利用が加速され、開発効率向上及びメンテナンスコスト削減が期待できる。

## MATLAB とは

MATLAB は 35 年以上の実績を持つソフトウェアであり、数値計算、可視化、プログラミングのための高水準言語による対話型の開発環境である。世界中で 400 万人を超えるエンジニアや科学者が、MATLAB を使用し、データ解析やアルゴリズムの開発、モデルやアプリケーションの作成を行い、アイデアの共有や専門分野を超えた共同プロジェクトのための共通言語として使用している。予知保全に関連する機能・ソリューションについて詳しく知りたい方は「予知保全」で検索。MATLAB による予知保全のビデオシリーズも公開されている [12]。

## 参考文献

[1] MathWorks, AutoML,

https://jp.mathworks.com/discovery/automl.html

[2] 予期せぬ稼働停止を防ぐ予知保全は有用か? -- 懐疑 論に打ち勝つための教訓

https://japan.zdnet.com/article/35158639/

[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.

http://data-acoustics.com/measurements/bearing-faults/bearing-3/

[4] MathWorks, "風力タービン高速ベアリングの経過予 測"

https://jp.mathworks.com/help/predmaint/ug/wind-turbine-high-speed-bearing-prognosis.html

[5] MathWorks, "予知保全で直面しやすい 4 つの課題と その対処法" (White Paper)

https://jp.mathworks.com/campaigns/offers/predictive-maintenance-challenges.html

[6] 田中 浩和, 加速試験の現状と課題, エレクトロニクス実装学会誌, 2010, 13 巻, 7号, p. 502-506

[7] Nectoux, Patrick, et al. "PRONOSTIA: An experimental platform for bearings accelerated degradation tests." IEEE International Conference on Prognostics and Health Management, PHM'12.. IEEE Catalog Number: CPF12PHM-CDR, 2012.

[8] An, Dawn, Joo-Ho Choi, and Nam Ho Kim. "Prediction of remaining useful life under different conditions using accelerated life testing data." Journal of Mechanical Science and Technology 32.6 (2018): 2497-2507.

[9] MathWorks, "Krones Develops Package-Handling Robot Digital Twin" (ユーザー事例)

https://jp.mathworks.com/company/user\_stories/krones-develops-package-handling-robot-digital-twin.html

[10] Mete Mutlu, John Kozicz, Transocean, Inc. "Condition and Performance Monitoring of Blowout Preventer (BOP) at Transocean" (Web セミナー) https://jp.mathworks.com/

videos/condition-and-performance-monitoring-of-blowoutpreventer-bop-at-transocean-1545303832202.html

[11] 井上道雄,"予知保全・故障予測 $\sim$  AI の実践的活用 例 $\sim$ " 保全学 Vol. 18-2, 2019

[12] MathWorks, "MATLAB/Simulink による予知保全ビデオシリーズ"

https://jp.mathworks.com/videos/series/predictive-maintenance.html

(2020年11月10日)

## 著者紹介



著著者: 井上 道雄

所属: MathWorks Japan

専門分野: 異常検知・故障予測



著者:王 暁星

所属: MathWorks Japan

専門分野:異常検知・故障予測

# ご意見お聞かせください

『保全学』では、読者からの声を募集しています。

本誌の内容に関するご意見・ご感想、こんな企画が欲しいなどのご要望、または 執筆者に対する具体的な質問でも構いません。闊達なご意見をお待ちしておりま す。

お名前(ふりがな)、ご所属、ご連絡先を明記の上、下記のQRコードから電子メールにてお送りください。郵送の場合は下記の住所まで。

「読者の声」欄で採用された場合は、イニシャルもしくは本名での掲載となります。

送付先: 〒 110-0008 東京都台東区池之端 2-7-17 井門池之端ビル 7 階

一般社団法人 日本保全学会 編集委員会宛

E-mail: secretariat@jsm.or.jp

