

少量の学習データで機器の劣化を 高精度に推定する物理モデル組み込みAI

栗山俊通*
Toshiyuki Kuriyama
脇本浩司†
Koji Wakimoto
蜂谷優人*
Yuto Hachiya

Physics-Embedded AI Accurately Estimating Equipment Degradation
from Small Amounts of Training Data

*AXイノベーションセンター
†同センター(博士(工学))

要 旨

三菱電機は、物理モデル(逆動力学モデル)を組み込んだ“物理モデル組み込みAI”によって、少量の学習データで機器の劣化を高精度に推定する手法を検討した。従来のAIによる劣化推定は大量の正常データを必要とし、運転パターンの変化や個体差に対して再学習が必要であった。今回の手法は物理的な大まかな挙動を事前に推定し、実測データで機器固有の傾向変動だけを効率的に学習することで学習データ量を大幅に削減する。実機評価(当社産業用ロボット)では学習データ量を約90%削減し、劣化推定性能(AUC)を従来手法の0.68~0.89から0.97~1.00へ向上させて、実際の機器を利用して模擬した劣化をほぼ全て推定できることを確認した。今後は、実際の利用シーンを想定した実証実験を進めて、2027年以降の製品化適用検討に進む。

1. ま え が き

製造現場では保守要員の高齢化・人手不足や素材コストの上昇によって、装置の故障や長期ダウンタイムが重大な经营风险になっている。従来のAIによる劣化推定は、大量の正常動作データから“正常範囲”を学習することで逸脱を検出する手法が主流だが、実際の現場では運転パターンの多様化や個体差、設置環境の違いによって、パターンごとの学習や再学習が必要になり、導入・維持の負荷が大きいという課題がある。

本稿では、機器の運動原理を表す逆動力学などの物理モデルをAIに組み込むことで、実測データが乏しい状況でも運転パターンの変化や個体差も含めて効率的に学習する手法について述べる。

2. Neuro-Physical AI

当社のAI研究開発は“自律性”“安全性”“物理世界での実効性”の三本柱で構成され、本稿はそのうち“物理世界での実効性”に焦点を当てる。物理世界での実効性とは実機での高精度な予測・制御・診断を実現する能力であり、実時間性や計算資源の制約、マルチフィジックス連携など現場固有の要請を満たすことを意味する。Neuro-Physical AIはこうした要請に応えるため、当社が長年にわたって蓄積した機器設計・制御・現場ノウハウと、数理・物理モデルをAI技術と融合する当社独自のフィジカルAI概念である。

2.1 研究開発戦略での位置付けと狙い

当社のAI研究開発戦略(図1)では、(1)自律性を担う“エージェントAI”(現場協調・タスク計画・意思決定)、(2)安全性を担う“セキュアAI”(セーフティー/セキュリティ統合、堅牢(けんろう)性・ガバナンス)、(3)物理世界での実効性を担う“フィジカルAI”の三本柱によって、他社差別化を狙う。エージェントAIはシステムの自律的最適化と人協調を、セキュアAIは安全・品質・信頼性を、フィジカルAIは実機での予測・制御・診断の精度と外挿性をそれぞれ強化し、製品群への横展開を加速する。本稿では、この三本柱のうち、フィジカルAIの概念と実装、及び劣化推定への適用を中心に述べる。




図1-当社のAI研究開発戦略

2.2 定義・基本要素と当社の強み

Neuro-Physical AIでのフィジカルAIの定義は、当社が持つ事業領域のドメイン知識と物理法則を融合し、機器やシステム全体を更に賢く、安全かつ信頼性高く動作させるフィジカルAIである。基本要素としては、逆動力学や流体・熱伝導などの物理モデルによるセンサー値の推定、その残差を学習するAIモデル、計算負荷を下げるためのサロゲートやシミュレーター連携、そしてエッジ実装を見据えたモデルのコンパクト化が挙げられる。当社の強みは、機器設計や制御理論に根ざした高精度な物理モデルを初期推定に用いることで、少量データでも迅速に高精度化が可能な点である。これによって実運用時の再学習負荷を低減し、実運用を考慮したAIソリューションを現場に提供できる。図解(図2)や実例を通じて、本稿では逆動力学を中心とした具体的な統合アーキテクチャーと期待される効果を示す。

当社が長年培ってきた事業領域や現場での知見・ノウハウと物理法則を融合し、
機器やシステム全体を更に賢くする、安全で信頼性の高い当社独自のフィジカルAI



図2- Neuro-Physical AI

3. AIによる劣化推定手法とその課題

本稿の対象は機器の劣化推定とする。この章では、センサーデータを用いた機器の劣化推定手法と、それに伴う現場導入の主要な課題について述べる。

3.1 データを利用した機器の劣化推定

製造現場の機器には位置・速度・加速度・トルク・温度など多種のセンサーが搭載されて、これらの時系列データを用いて機器の状態を監視する事例が多い。機器が長期使用で劣化すると、例えばベルトの緩みやギヤの潤滑低下に伴って指令に対して必要なトルクが変化するなど、センサーデータに微小な変動が表れるという前提に基づいて劣化推定が行われ

る。劣化は直接観測できないことが多いため、センサーデータの統計的特徴や周波数成分、相関構造の変化を抽出して正常時の振る舞いからの逸脱を検出する。しかし劣化に伴ってデータに表れる変化は機器ごとに大きく異なることが多く、同じ劣化カテゴリーでもセンサー変動の特徴が異なることが頻繁にある。このため従来は機器の専門家が個別に特徴設計・しきい値設定・前処理ルールを作り込んで、ドメイン知識を反映した劣化推定ロジックを構築して運用してきた。こうした手作業による作り込みは高い精度になる一方で、専門人材の工数を多く消費し、新機種や運転条件の変化ごとに再設計・検証が必要になるため、スケール化や迅速な現場導入が難しいという課題も存在する。

3.2 劣化推定へのAI活用

近年、機械学習や深層学習を用いて大量の運転データから“正常範囲”を学習し、そこからの逸脱をもって劣化や異常を判断する手法が広く採用されている。データのばらつきを考慮したデータの変化を捉える能力によって、人手では見落としやすい前兆を推定できる点が利点である。典型的なアプローチは正常動作データを用いた再構成誤差や確率分布の学習であり、学習済みモデルが示す正常領域からの有意な外れ値を劣化と判定する(図3)。




図3-AI活用による機器の劣化推定

3.3 従来手法の課題

AIを利用した従来手法には現場導入での実務的な課題が複数存在する。第一に、正常範囲を安定的に学習するには多様な運転パターンを網羅した大量データが必要であり、パターンごとに学習やしきい値調整が求められるとデプロイの負担が増す。第二に、学習データに含まれない運転条件や個体差に対する外挿性能が低く、未学習パターンでの誤検知や見逃しが発生しやすい。それに加えて、誤報が増えると現場の対応負担が増大し信頼を失うため、継続的な再学習・運用監視・しきい値調整のための人手やコストが実用化の障壁になる。これらの課題を解決するためには物理知見の活用による学習データの削減、未学習パターンでも学習可能な機構が求められる。

4. 物理モデル組み込みAIとその効果

この章では、産業用ロボットを対象とし、ロボットが従う物理モデル(逆力学モデル)をAIに組み込む手法について述べる(図4)。また、実機を利用した実証結果についても併せて述べる。

4.1 物理モデル

センサーだけのデータから機器挙動を完全に再現することは困難である。測定ノイズやセンサーの取付け差、運転条件の多様性によって生じる変動を全てデータ駆動で吸収しようとする膨大な学習データが必要になるためである。そこで今回の研究では産業用ロボットの剛体動力学を物理モデルとして採用した。ロボットの運動を表す位置 q 、速度 $\dot{q}$ 、加速度 $\ddot{q}$ といった動力学情報を入力とし、各軸に必要なトルク τ を推定する逆力学モデルを用いる(図5)。逆力学は $\tau = M(q)\ddot{q} + C(q, \dot{q})\dot{q} + g(q) + F(q, \dot{q})$ のように慣性項($M(q)\ddot{q}$)・コリオリ項($C(q, \dot{q})\dot{q}$)・重力項($g(q)$)・摩擦項($F(q, \dot{q})$)で構成され⁽¹⁾、これによって指令された動作から理論的に必要な大まかなトルク挙動を事前に算出できる。物理モデルによる基準推定は未学習の運転パターンでも一定の外挿性を持って、後段のデータ駆動処理が解くべき課題を“物理挙動との差分(残差)”に限定することで学習負担を大幅に低減する手法を開発した。




図4-物理モデル組み込みAI

モノ（機器）を“こう動かしたい”という情報から、これだけの“力（＝トルク）”が必要を求めるモデル




図5-逆力学モデル

4.2 AIへの組み込み

逆力学で得た物理推定値と実測トルクとの残差に着目し、その“傾向変動”をAIで補正するのがこのアプローチの核心である。ロボットの動力学情報は制御指令として事前に取得可能なため、これらの情報を物理モデルへの入力として用いることで監視対象トルクの基準推定を事前に行える。実測と推定の残差には機器個体差、設置誤差、温度などの環境要因が反映されるため、AIはこの残差だけを少量データで学習すればよく、結果として学習データ量の大幅削減が可能になる。また、物理モデルが基準挙動を与えるため、従来のように運転パターンごとに正常範囲を学習・管理する必要がなく、未学習の運転パターンに対しても物理推定を起点に外挿的に挙動を評価できる点が運用上の大きな利点である（図6）。

4.3 実証実験

方式の有効性を確認するため、当社製の6軸産業用ロボットを用いて二段階の実証実験を行った。実験①はピック＆プレース動作を対象とした正常範囲設定の検証で、従来手法と比較して正常性を判定するために必要な学習データ量を評価した結果、物理モデル組み込みAIは学習データ量を約90%削減（学習データ数：約200→約20）して同等以上の正常範囲設定を達成した。実験②は軸摩擦を模擬するために6軸のうち一つの軸の潤滑剤を除去して加速試験で異常停止まで収集したデータを用いたものである。ここではピック＆プレースの速度を変えた二つの運転パターンを定義し、片方のパターンで学習したモデルを未学習のもう片方に適用して劣化推定が可能かを検証した。評価はROC (Receiver Operating Characteristic) /

AUC(Area Under the Curve)で行い、従来手法に対して約30%相当の性能向上(従来手法：0.68~0.89→提案手法：0.97~1.00)を確認した。これによって、実際の機器を利用して模擬した劣化をほぼ全て推定できて、学習負荷削減と未学習パターンへの外挿性向上の両立を実証した。今後は、評価対象装置の拡大や故障種別の増強などを進める予定である。




図6-正常範囲設定への物理モデル組み込みAI適用

5. む す び

逆動力学に基づく物理モデルをAIに組み込んで、機器の動力学情報から事前にトルク挙動を推定し、その残差を少量データで学習する手法を示した。実機評価では学習データ量を約90%削減し、劣化推定性能(AUC)を約30%向上させる結果を得た。物理モデルが大まかな基準挙動を担保することで未学習の運転パターンへの外挿性が確保され、誤検知抑制と高精度化を両立できる点がこの手法の大きな強みである。

今後は実験設定を拡張して試験規模や故障種別を増やして、評価の深掘りを行うとともに、エッジ実行やオンライン同定を含む実運用要件を整備して、2027年以降の製品適用に向けた検討を進めていく。

参 考 文 献

- (1) Siciliano, B., et al. : Robotics: Modelling, Planning and Control, Springer Science & Business Media (2010)