

機器の異常予兆検知と原因特定が可能な物理式を自動生成する機械学習技術

Machine Learning Technology for Automatically Generating Physical Formulas to Enable Predictive Detection of and Identify Causes of Device Anomalies

鈴木 智之 SUZUKI Tomoyuki 廣畑 賢治 HIROHATA Kenji 伊藤 安孝 ITO Yasutaka

人々の生活を支えるインフラ機器を安心・安全に使い続けるためには、入念な設計・製造だけでなく、運用中に異常の予兆を捉えて的確に保全することが重要である。しかし、異常発生メカニズムは複雑なため、センサーの異常波形を検知する従来技術では、原因の特定が難しかった。

東芝は、機器の温度を推定するシンプルな物理式を、複数の測定点温度の時系列データから自動生成する機械学習技術を開発した。物理式と現象は対応付けしやすいため、原因の特定が容易になる。詳細数値解析との比較検証を行い、生成された物理式は詳細数値解析によく一致する結果を短時間で算出できることを確認した。この技術で運用中に温度を推定して、その変化から異常予兆を検知することで、異常原因の特定も可能になる。

Scrupulous design and manufacturing alone are insufficient to ensure continued safe, secure operation of infrastructure devices that serve as the backbone of society. Precision maintenance with prediction of anomalies during operation in mind is also vital. The mechanism that triggers anomalies, however, is complex, making it difficult for conventional technologies to detect anomalous sensor waveforms.

Toshiba Corporation has developed machine learning technology that automatically generates simple physical formulas which estimate device temperatures from the time series data of multiple temperature measurement points. Physical formulas and phenomena are easy to associate, making it easy to determine the cause of anomalies. Comparative evaluation of detailed numerical value analysis confirms that the generated physical formulas can calculate results that correspond well with the detailed numerical value analysis in a short period of time. This technology can estimate operating temperatures and detect predicted anomalies from changes to identify the cause of such anomalies.

1. まえがき

社会インフラを支えるインバーターなどの機器やシステム（以下、インフラ機器と略記）の予期せぬ運転停止は社会や産業へ大きな影響を与えるため、回避する必要がある。例えば、インフラ機器の経年劣化は温度と密接な関係にあり、温度が10℃上がると寿命が1/2になるといわれる電子部品もある。そのため、設計に冗長性を持たせたり、定期的に保全したりといった対策を行ってきた。しかし、インフラ機器は使用条件や稼働環境が様々であるため、事前に決めた基準に基づく対策だけでは不十分なことが多い。一方、過剰な対策は、導入費・運用費だけでなく、環境負荷も増大させる。

このような中、機器の状態を監視して適時適度に保全する、予知保全の重要性が高まっている。特に、インフラ機器は異常発生のメカニズムが複雑なものが多いため、異常予兆を検知するだけでなく、その原因特定と対策立案が求められる。

東芝は、インフラ機器で発生する故障の主原因である、搭載部品の発熱に注目し、複数箇所の温度の時系列データから、温度を推定する物理式（物理量の関係を表現す

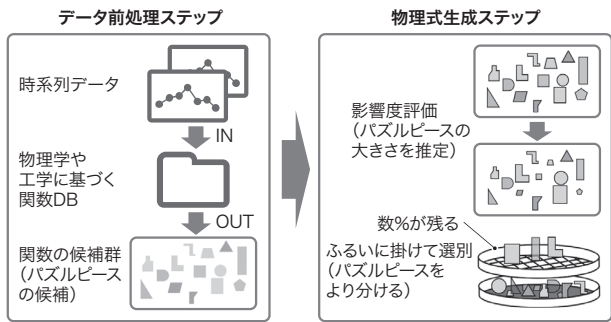
る方程式）を自動的に生成する、機械学習技術を開発した^{(1),(2)}。各測定点の温度同士の関係を、物理学や工学に基づく関数の組み合わせで表現した。関数の候補は膨大にあり、独自開発の機械学習技術で適切な組み合わせを効率的に見つけ出す。物理式と実際の現象の対応付けは容易なため、開発技術を予知保全に応用すれば、異常予兆を検知するだけでなく、その原因特定と対策立案が可能になる。

ここでは、開発技術の概要、実効性検証、及び予知保全への適用について述べる。


2. 物理式を自動生成する機械学習技術

当社は、時系列データから物理式を自動生成する機械学習技術を開発している。この技術では、物理学や工学に関する理論式や経験式を基に構築した関数DB（データベース）から、与えられた時系列データを説明するために適した関数の組み合わせを効率的に探索する。

物理式の自動生成の概要を、パズルに見立てて説明する（図1）。データ前処理ステップでは、時系列データを関数DBに入力し、物理式を構成する関数の候補群、つまり、パズルピースの候補に成形する。次に、物理式生成ステッ



(a) 物理式を自動生成するための二つのステップ



(b) 自動生成した物理式

$T=T_1, T_2, \dots$ $X=X_1, X_2, \dots$ X_i : 物理式に使われる物理量

図1. 物理式の自動生成の概要

時系列データをパズルピースの候補に成形し、それらの影響度を評価し、ふるいに掛けてより分ける。

Overview of physical formula generation

では、各パズルピースが時系列データに与える影響度を評価して、ふるいに掛けてパズルピースをより分ける。最後に、残った少数のパズルピースでパズル、つまり物理式を組み立てる。この物理式は、測定点同士の温度の関係を少数個の関数で表現するネットワークとして得られるので、容易に理解できる。

温度の1次元シミュレーション方法である熱回路網法の式(1)を用いて、データ前処理ステップを詳細に述べる。

$$\frac{dT_n}{dt} = \frac{Q_n}{C_n} + \sum_{j=1, j \neq n}^N \frac{1}{C_n R_{nj}} (T_j - T_n), \quad n=1, 2, \dots, N \quad (1)$$

ここで、 T は温度、 Q は発熱量、 t は時間、添え字の n 、 j は温度測定点の番号、 N は測定点の個数、 C 、 R は対象物の形や材質や温度で値が決まる関数である。 R は風速など放熱環境にも依存するため、温度の3乗や風速の0.5乗などを含む、様々な形の関数が提案されている。式(1)の左辺は単位時間あたりの温度変化量であり、右辺の第1項は発熱量に、第2項は周囲の温度測定点との熱交換量に関係する。

このように様々な関数を用いて関数DBを構築した。関数DB内の関数を h 、 m と n をその番号とすると、式(1)は式(2)のように変形できる。

$$\frac{dT_n}{dt} = \alpha_0 Q_1 + \dots + (\alpha_m h_m + \alpha_{m+1} h_{m+1} + \dots)(T_1 - T_n) + \dots + (\alpha_n h_n + \alpha_{n+1} h_{n+1} + \dots)(T_N - T_n) \quad (2)$$

式(2)は物理式の型である。データ前処理ステップでは、時系列データを用いて係数 α 以外の $(dT_n)/dt$ や h を計算する。これにより、 $1=2\alpha_0+4\alpha_1+\dots$ といった単純な式を時系列データの数だけ作成する。

図1の物理式生成ステップでは、スパースモデリングという機械学習を用いて係数 α を推定する。不要な関数候補の係数 α をゼロにすることで、関数を選別する。これを効率的に実施するために、最新のスパースモデリング技術であるSINDy⁽³⁾に三つの改良を加えた⁽²⁾。具体的には、①誤差同士の相関を簡便に考慮できるデータ前処理方法、②関数の候補同士の相関が高い場合に有効な係数推定方法、③関数の候補の適切な組み合わせを実現するための空間探索方法である。

3. 実効性検証


3.1 検証方法

開発した技術の実効性を、詳細数値解析によるデータと比較することで検証した。パワーモジュールと放熱板で構成するインバーターを自然空冷する場合の詳細数値解析により、インバーター各部の温度の時系列データを得た。自然空冷では、自然対流とふく射で放熱する。自然対流とふく射の放熱能力は機器の温度に依存して時々刻々と変わるため、通常の機械学習によるモデル化は難しい。詳細数値解析には、熱の分野で一般的な有限体積法を用いた。この方法は現象を精度良く再現できるが、多くの物理情報と長い時間を要する。

図2(a)に、実効性検証に用いるデータ取得の概要を示す。詳細数値解析の条件として、パワーモジュール上のチップ合計24個分の各発熱量、周りの空気温度、及び部品温度、合計26個の変数の初期値を入力する。出力された数百万か所の温度から、約130か所分を抜き出して、実効性検証用データセットとする。

図2(b)に、解析条件の例を示す。26個の変数の初期値を変えて、実効性検証用データセットを作成する。開発した機械学習技術による物理式生成に用いる15個の学習データセットと、7個の評価データセットを作成した。

学習データセットの初期値の定義域は、空気温度及び初期温度が5～45℃、発熱量が0～18Wである。評価データセットは、空気温度60℃、発熱量30Wなどを含む。これは学習データセットの定義域の外側であり、外挿に相当する。



記号	空気温度 (°C)	部品温度 (°C)	発熱量 (W)					
			パワーモジュール1			パワーモジュール2		
			チップ1	チップ2	チップ12	チップ1	チップ12	
L1	25	25	15	14	1	1	10	
L2	45	45	6	5	15	0	9	
⋮								
T1	60	60	12	11	0	12	0	
⋮								

(b) 解析条件の例

L1~L15: 学習データセット取得のための解析条件
T1~T7: 評価データセット取得のための解析条件

図2. 詳細数値解析による実効性検証用データの取得

自然空冷するインバーターの詳細数値解析で得た時系列データから実効性検証用データセットを作成し、開発した技術による物理式生成と、その評価に用いる。

Acquisition of viable data for verification via detailed numerical value analysis

実効性検証は二つの観点で行った。一つ目は、起きている現象を正しく識別し、物理的に妥当な物理式を生成できたかどうかである。二つ目は、物理式を用いて高精度な温度推定計算を素早く実施できたかどうかである。

3.2 検証結果

自動生成した物理式の一部を図3に示す。物理式は少数の関数で構成され、分かりやすい。これは、影響度を評価してふるいに掛け、約98%の係数をゼロにした結果である。式(3)からチップ1が発熱源であること、式(4)及び(5)からチップの発熱が放熱板やケースへ順々に伝わり、自然対流やふく射によって放熱する現象が分かる。式(5)を基に、 T_{109} と、 $T_{106} \cdot T_{107} \cdot T_{108}$ の関係を推定したネットワークを図3右下に示した。

物理式を用いた温度推定計算の結果を、詳細数値解析の結果と比較した。7個の評価データセットに対する二つの手法間の誤差は0.4~0.9°C、平均0.6°Cであり、よく一致した。この計算に、物理式は汎用のパソコンで数秒を、詳細数値解析は高性能なコンピューターで約1日を要した。物理式を生成する時間は数分から十数分であり、これを含めても、計算時間を大幅に短縮できることが分かった。

図4に、物理式と詳細数値計算による結果を比較して示

$$\frac{dT_1}{dt} = 1.1(T_{37} - T_1) + 0.13Q_{1M1} \quad (3)$$

$$\frac{dT_{100}}{dt} = 1.6 \times 10^{-3}(T_{101} - T_{100}) + 1.5 \times 10^{-3}(T_{102} - T_{100}) + 6.3 \times 10^{-5} \sqrt{2 \frac{T_{in} - T_{100}}{T_{in} + T_{100}}} (T_{in} - T_{100}) + 9.4 \times 10^{-13}(T_{in}^4 - T_{100}^4) \quad (4)$$

$$\frac{dT_{109}}{dt} = 0.23(T_{106} - T_{109}) + 0.053(T_{107} - T_{109}) + 0.056(T_{108} - T_{109}) + 6.0 \times 10^{-3} \sqrt{2 \frac{T_{in} - T_{109}}{T_{in} + T_{109}}} (T_{in} - T_{109}) + 8.2 \times 10^{-12}(T_{in}^4 - T_{109}^4) \quad (5)$$




図3. 自動生成した物理式の例

チップの発熱が放熱板やパワーモジュールのケースへ順々に伝わり、自然対流やふく射で外へ放熱する現象を分かりやすくモデル化した。

Example of automatically generated physical formula





図4. 物理式と詳細数値解析による温度推定結果の比較

物理式を用いた計算は、詳細数値解析の結果と、誤差1°C未満でよく一致した。

Comparison of estimated temperature results via physical formula and detailed numerical value analysis

す。図4(a)は、空気温度として、学習データセットの上限値45°Cよりも高い60°Cを設定した場合である。学習範囲外でも、チップの急激な温度上昇、及び放熱板などの緩やかな温度上昇の物理式による値は、詳細数値解析とよく一致

した。図4(b)は24個の発熱量の値が時間とともに変わる場合である。このような場合でも、物理式と詳細数値解析はよく一致した。

この検証で、学習データセットを取得するために実施した詳細数値解析の回数15は、変数の数26より少ない。一般的な技術で温度推定のための近似式を生成する場合は、変数の数より多い回数の詳細数値解析を必要とする。物理式生成のためのデータ準備の労力が小さいことは、実用上の大きな特長である。

生成した物理式が物理的に妥当で、発生している現象に容易に対応付けでき、詳細数値解析と同等の精度で高速に温度を推定できることを検証した。自然空冷のほか、強制空冷や、接触状態が変わる現象にも適用可能なことも、検証済みである^[2]。

4. 予知保全への適用

開発技術を用いた物理式の自動生成に、温度測定点の位置や材質などの情報は必要ない。入力変数と、センサーで測定した温度の時系列データで十分である。例えば、インフラ機器の運用中に物理式を作り直して変化を見ることで、どの温度測定点間に、どんな変化が起こったかを判断できる。すなわち、異常予兆の検知と、その原因特定及び対策立案が可能になる。

図5に、開発技術をインフラ機器の予知保全に適用するイメージを示す。4台あるパワーモジュールのうち1台が放熱板と接触不良を起こすことを想定する。運用初期の物理式を、正常状態と仮定する。定期的に物理式を作り直して α の差分を見ることで、接触不良が原因で冷却能力が劣化




図5. インフラ機器の予知保全への適用

物理式の変化を見ることで、4台あるパワーモジュールのうち1台が放熱板と接触不良を起こしたことを検知する。

Application to infrastructure device predictive maintenance

したことが検知できる。これを基に、グリース蒸発の有無を確認するという対策まで、遠隔地に居ながら立案できる。

インフラ機器の経年劣化は温度と密接な関係にあるため、冷却能力の劣化を検知して早期に回復することは長寿命化に貢献する。また、重要部品の推定温度を用いて寿命予測計算すれば、適切な部品交換時期や買い替え時期が分かる。このような物理的根拠に基づく保全計画は、ユーザーに納得感を与えられる。

5. あとがき

複数の測定点温度の時系列データから、温度を推定する物理式を自動生成する、独自開発の機械学習技術について述べた。得られた物理式からは発生している現象が分かりやすく、詳細数値解析と同等の精度で高速に温度の推定値を計算できる。この技術を予知保全へ適用することで、異常予兆の検知と原因特定が可能になる。

現在、この機械学習技術をインフラ機器に搭載する検討を進めている。今後、更に高性能化を図り、インフラ機器を安心・安全に使い続けるための運用サービスを実現していく。

文献

- (1) 東芝. “機器の時系列データから解釈性に優れた物理モデルを自動生成し、機器の「異常検知」と「異常発生要因の判定」が可能なAI技術を開発”. 研究開発ニュース. <<https://www.global.toshiba/jp/technology/corporate/rdc/rd/topics/21/2111-01.html>>, (参照 2023-04-12).
- (2) Suzuki, T. et al. Physics-Informed Machine Learning for Surrogate Modeling of Heat Transfer Phenomena. Journal of Computational and Nonlinear Dynamics. 2023, **18**, 11, p.111001-1 - 111001-15. <<https://asmedigitalcollection.asme.org/computationalnonlinear/article/18/11/111001/1166452/Physics-Informed-Machine-Learning-for-Surrogate>>, (accessed 2023-09-04).
- (3) Brunton, S. L. et al. Discovering governing equations from data by sparse identification of nonlinear dynamical systems. Proceedings of the national academy of sciences. 2016, **113**, 15, p.3932-3937.



鈴木 智之 SUZUKI Tomoyuki
研究開発センター 知能化システム研究所
機械・システムラボラトリー
日本機械学会会員
Mechanical Systems Lab.



廣畑 賢治 HIROHATA Kenji, D.Eng.
研究開発センター 知能化システム研究所
博士(工学) 日本機械学会・米国機械学会・IEEE・
電子情報通信学会・エレクトロニクス実装学会会員
Advanced Intelligent Systems Lab.



伊藤 安孝 ITO Yasutaka
研究開発センター 知能化システム研究所
機械・システムラボラトリー
日本トライボロジー学会・日本機械学会会員
Mechanical Systems Lab.