

設備の時系列センサーデータを用いた機械学習による異常診断手法

Fault Diagnosis Method Based on Machine Learning using Time-Series Sensor Data

植野 研 UENO Ken 山口 晃広 YAMAGUCHI Akihiro 真矢 滋 MAYA Shigeru

近年、IoT (Internet of Things) 技術の進展に伴って、社会インフラや製造現場の設備を監視するための時系列センサーデータ(以下、時系列データと略記)が容易に入手できるようになってきている。特にこれら設備の状態監視では、大量かつ高頻度に取得される時系列データを異常検知や状態予測に活用したいという強いニーズがある。

東芝は、これらのニーズに応えるため、時系列データを活用した機械学習による異常診断手法として、正常から異常な状態への変化傾向を正確に警告する異常検知、正常状態の時系列データの波形パターンだけを学習することで異常判定の根拠を明示する異常検知、及び時系列データの波形パターンを常に学習し続けて多様な変化に追従する状態予測の各手法を開発し、設備の運用・保守へ適用することを目指して基本性能の検証を進めている。

The progress of Internet of Things (IoT) technologies has expedited the collection of time-series sensor data from various equipment in social infrastructure facilities and manufacturing sites. Particularly in the case of facility monitoring systems, attention is being increasingly focused on the effective utilization of large volumes of time-series data for anomaly detection and prediction.

In this context, Toshiba Corporation has developed a fault diagnosis method incorporating the following methods based on machine learning: (1) anomaly detection to warn of the risk of changes from normality to abnormality with certainty, (2) anomaly detection to offer grounds for abnormality determination by learning normal waveform patterns of time-series data, and (3) anomaly prediction to follow numerous state variations by continuously learning the waveform patterns of time-series data. We are now carrying out the verification of elemental performance aimed at the practical application of these methods to the operation and maintenance of a wide variety of facilities.

1. まえがき

社会インフラや製造現場における設備の運用・保守には、膨大な時間とコストが掛かる。近年、IoT技術の進展に伴って、様々なセンシング技術や、データ通信技術、データ収集・管理技術などにより、膨大なデータを低コストで入手し活用することが可能となってきている。しかし、収集された監視データに基づいて設備の状態を判断しているのは監視員であり、膨大な量の監視データを、常に、くまなく注視し続けることは難しい。また、監視対象が増大するのに合わせて、監視員・保守員も増やしていくことは困難なため、監視業務の効率化が強く求められている。このような背景から、近年、監視データに基づく異常検知・状態予測を機械学習技術で実現するために、時系列データに基づく異常検知・予測手法が注目を集めている。

社会インフラや製造現場の設備では、基本的に正常状態であることが求められるため、通常、異常検知のために異常状態のデータを収集することは困難である。したがって、多様な正常状態の時系列データから正常範囲を学習し、正常状態からどの程度逸脱しているかを精度良く判定すること




図1. 異常診断手法の分類

時系列データを活用した波形異常診断は、異常検知、状態予測の二つに大別される。更に異常検知には、正確に異常傾向を警告可能な明瞭型と、判定の根拠を明示的に示すことができる根拠あり型の2種類がある。

Classification of fault diagnosis methods using time-series waveforms

が求められる。また、適用対象によっては、なぜその判定結果が出たのか、明確な根拠を示すことも要求される。

東芝は、この異常検知の課題に対して、明瞭型と根拠あり型の二つのアプローチで開発を進めている(図1)。一つ目は、正常状態からの逸脱が起こった場合に、異常度合いを提示し正確に警告する明瞭型アプローチに基づく異常検知手法 dLSTM (delayed Long Short-Term Memory)^(注1)

である⁽¹⁾。開発したdLSTMは、正常状態にある時系列データの多様な変化を常に学習することで、正常状態から異常状態に傾向が変化した際に、明瞭に異常警告を発報することができる。二つ目は、正常状態だけの時系列データの波形に基づき多様な正常状態の波形パターンを学習し、異常判定の根拠として特徴的な部分波形のパターンを示せる根拠あり型のアプローチである波形分類手法OCLTS (One-Class Learning Time-series Shapelets)^(注2)である^{(2), (3)}。開発したOCLTSにより、学習時に異常データがなくても異常を検知することができる。

更に、社会インフラや製造現場の設備では、時々刻々と環境や稼働状態が変化する中で、絶え間なく取得される時系列データから、精度良く将来の稼働状態を予測することが求められる。当社は、この状態予測の課題に対して、直近の稼働状態の変化と、長期的に繰り返される稼働状態の変化パターンに関する情報をバランス良く学習するアプローチを取ることで、環境や稼働傾向に変化が生じても将来値を精度良く予測できる、波形パターンに基づく予測手法OPOSSAM (Online Prediction Of Stream data with Self-Adaptive Memory)^(注3)を開発した^{(4), (5)}。

ここでは、開発した三つの異常診断手法の概要と特長について述べる。

2. 異常傾向を正確に警告する異常検知手法 dLSTM

工場などの製造現場では、製造装置のメンテナンスが定期的に実施されるが、製造装置は、稼働状態が変わると、メンテナンスが必要となるタイミングも変わってくる。また、一般に、製造装置はメンテナンス時期が近づくと一時的に異常状態に向かう性質があるが、これを除いたほとんどの時間では正常であり、正常状態の時系列データだけが収集される傾向にある。

そこで当社は、時系列データに適した深層学習 LSTM (Long Short-Term Memory) を改良し、正常時系列データだけから多様な正常状態を学習し、正常状態からの逸脱度を計算することで正確に異常傾向を発報できる異常検知手法 dLSTM (図2) を開発した。従来のLSTMでは、多様な稼働状況の変化を捉えることは困難であった。しかし、dLSTMでは、過去の時系列データであらかじめ複数の異常検知モデルを構築しておき、異常判定のタイミングを少しだけ遅らせ、現在のデータを用いて、どの異常検知モデル




図2. dLSTMでの最良の異常検知モデルの選択

まず正常状態の時系列データの学習に基づいて複数の異常検知モデルを構築し、次に実データを参照して最良の異常検知モデルを選択する。判定時には、このモデルを用いて、未知データの異常スコアを算出する。

Selection of anomaly detection model in delayed long short-term memory (dLSTM) method




図3. dLSTMによる異常検知の例

開発したdLSTMは、従来手法に比べて、より明瞭に異常傾向を検知できており、異常警告が可能になる。

Comparison of anomaly detection using conventional and dLSTM methods

が現在の稼働状況に適しているかを評価することで、直近の状況変化に対応した最良の異常検知モデルを選択することができる。その結果、複雑な時系列変化に追従でき、正確な異常検知が可能になる。図3に示すように、dLSTMでは、不具合が起こったタイミングで、従来手法であるLSTM⁽⁶⁾よりも、明確に異常スコアが急上昇していることを確認した。これは、直近の急激な時系列変化を正確に捉える複数の異常検知モデルを正しく選択できたためと考えられる。今後、実際の現場で、dLSTMの実適用の検討を進めていく。

(注1) 正常データだけから深層学習モデルを複数構築し、実データにフィットしたモデルで正確に異常を警告する異常検知手法。

(注2) 正常データだけから代表的な波形パターンを学習する異常検知手法。

(注3) 短期記憶と長期記憶を適応的に用いるオンライン予測手法。

3. 正常時系列波形に基づく説明性の高い異常検知手法 OCLTS

電力やビルなどの社会インフラ設備の稼働状態を監視する現場では、様々な時系列データが収集され、活用されている。社会インフラ分野においては、安全性の観点から、判定根拠を重視する傾向があり、なぜ異常と判定したか、その根拠を明示的に示す必要があるケースが多い。また、製造現場と同様に、社会インフラ設備も基本的には正常状態であり、メンテナンスの時期が近づくと正常状態から異常状態へと向かう兆候だけが見られるのが一般的である。これまで、異常と判断した根拠を示す説明性の高い時系列データの異常検知では、学習データとして正常と異常の両状態のデータが必要であった^{(7), (8)}。

そこで、当社は、正常状態の時系列データの波形だけから、正常状態に特徴的な部分波形パターンと、1クラス分類器^(注4)を同時に学習する手法 OCLTSを開発した(図4)。

現在、様々な社会インフラ設備の異常兆候を検知するため、OCLTSの性能評価と改良を進めており、監視業務の効率化を目指している。

4. 多様な変化に追従する状態予測手法 OPOSSAM

社会インフラ設備の中でも、特に電力や、ビル、道路などは、設備の利用状況がダイナミックに変化する。そのため、時系列データの変化の傾向を正確に捉え、保守のタイミングを見極めて部品交換や清掃などのメンテナンス作業を効

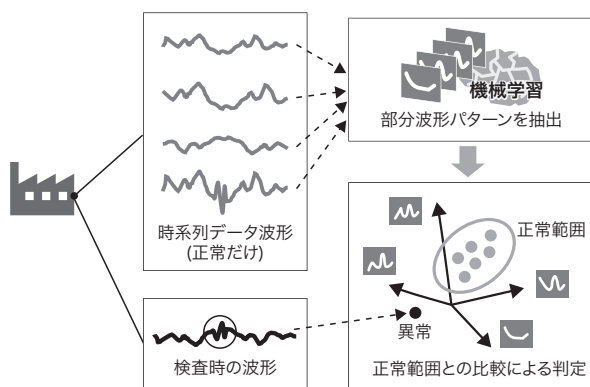


図4. OCLTSの概要

正常データの特徴的な部分波形パターンを抽出し、多様な正常状態の波形パターンから算出される正常範囲から逸脱する場合、異常と判定する。

Outline of one-class learning time-series shapelets (OCLTS) method

(注4) 一つのクラスの学習データだけから、そのクラスとそれ以外とを判別する自動分類手法。

率化することが必要である。しかし、これまでの手法では、膨大な過去の時系列データにおける変化の傾向を押しなべて学習するため、直近の利用環境の変化に合わせて将来値を正確に予測することは困難であった。

そこで当社は、過去の時系列データの中から繰り返し現れる波形パターンとその時点での予測対象の実績値、及び直近の傾向変化を表す波形に基づき将来予測値を算出する予測手法 OPOSSAMを開発した(図5)。OPOSSAMは、現在の値とできる限り一致するように学習した予測モデルを常に学習し続けるオンライン学習を適用することで、短期的な将来値を正確に算出する。

時系列公開データを用いた予測性能のベンチマークを実施し、OPOSSAMは、従来のオンライン学習手法であるARWin^{(注5), (9)}、KRWIn^{(注6), (10)}よりも高精度な予測ができることを確認した(図6)。今後、様々な現場で予測性能を検証し、実用化を目指していく。

5. あとがき

社会インフラや製造現場における監視業務の効率化を目指した異常検知手法、状態予測手法について述べた。異常検知手法では、状況変化に強く正確に異常傾向を警告できるdLSTM、特徴的な部分波形パターンを根拠として異常を判定するOCLTSの2種類を開発した。また、状態予測手法では、多様な変化に追従し短期的な将来値を正確に予測するOPOSSAMを開発した。

現在、東芝グループの社会インフラ事業・製造部門と協




図5. OPOSSAMの概要

絶え間なく取得される時系列データの中で、長期的に繰り返される代表的なパターンだけを保持しておき、短期的な傾向とのバランスを現在値から常に学習して、将来の予測値を算出する。

Outline of online prediction of stream data with self-adaptive memory (OPOSSAM) method

(注5) 様々な窓幅で線形予測した結果を統合して予測する従来手法。

(注6) 滑走窓を用いてカーネルリッジ回帰で予測する従来手法。

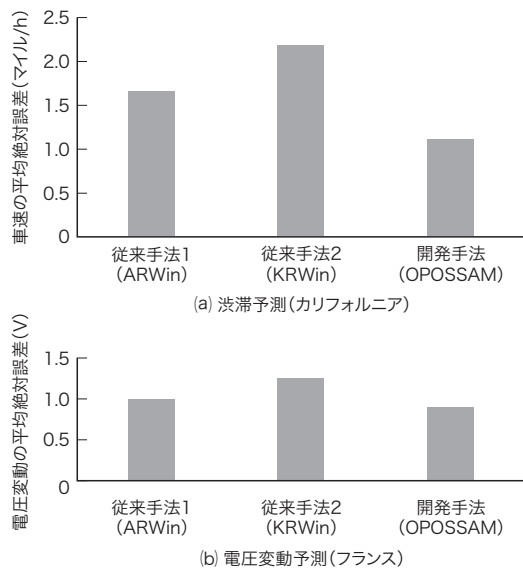


図6. 時系列公開データによる予測性能のベンチマーク結果の例

開発したOPOSSAMは、電圧変動予測、及び渋滞予測において、従来手法のARWin, KRWinよりも平均絶対誤差が小さく、精度が良いことを確認した。

Results of benchmark comparison of prediction errors in case of using public time-series datasets

方し、実環境での実証試験を進めている。近い将来、実際の事業に活用することで、より多くの設備の運用・保守を効率良く進められるようになると考えている。

文献

- (1) Maya, S. et al. dLSTM: a new approach for anomaly detection using deep learning with delayed prediction. International Journal of Data Science and Analytics (IJDSA). 2019, p.1-28. <<https://doi.org/10.1007/s41060-019-00186-0>>, (accessed 2019-06-21).
- (2) Yamaguchi, A. et al. OCLTS: One-Class Learning Time-Series Shapelets. International Journal of Data Mining Science (IJDAT). 2019, 1, 1, p.24-32.
- (3) Yamaguchi A.; Nishikawa, T. "One-Class Learning Time-Series Shapelets". Proceedings of 2018 IEEE International Conference on Big Data. Seattle, WA, 2018-12, IEEE. 2018, p.2365-2372.
- (4) Yamaguchi, A. et al. OPOSSAM: Online Prediction of Stream Data with Self-Adaptive Memory. International Journal of Data Mining Science (IJDAT). 2019, 1, 1, p.33-43.
- (5) Yamaguchi, A. et al. "OPOSSAM: Online Prediction of Stream Data Using Self-adaptive Memory". Proceedings of 2018 IEEE International Conference on Big Data. Seattle, WA, 2018-12, IEEE. 2018, p.2355-2364.

- (6) Chauhan, S.; Vig, L. "Anomaly detection in ECG time signals via deep long short-term memory networks". Proceedings of 2015 IEEE International Conference on Data Science and Advanced Analytics (DSAA). Paris, France, 2015-10, IEEE. 2015, p.1-7.
- (7) 植野 研, ほか. 時系列波形分類学習による低スペックセンサ信号からの状態判別. 信学技報. 2010, 109, 473, p.23-26.
- (8) 吉岡賢司, ほか. エレベーター遠隔監視におけるセンサネットワークの構築. 東芝レビュー. 2012, 67, 11, p.28-31.
- (9) Yoshida, S. et al. Adaptive Online Prediction Using Weighted Windows. IEICE Transactions on Information and Systems. 2011, E94.D, 10, p.1917-1923.
- (10) Van Vaerenbergh, S. et al. Nonlinear System Identification using a New Sliding-Window Kernel RLS Algorithm. Journal of Communications. 2007, 2, 3, p.1-8.



植野 研 UENO Ken, Ph.D.

研究開発本部 研究開発センター システム技術ラボラトリー
博士 (政策・メディア)
人工知能学会・電子情報通信学会・IEEE・ACM 会員
System Engineering Lab.



山口 晃広 YAMAGUCHI Akihiro, Ph.D.

研究開発本部 研究開発センター システム技術ラボラトリー
博士 (情報科学)
情報処理学会会員
System Engineering Lab.



真矢 滋 MAYA Shigeru

研究開発本部 研究開発センター システム技術ラボラトリー
人工知能学会会員
System Engineering Lab.