

大規模プラントの状態変化の中に埋もれた異常を早期かつ高精度に検知する異常予兆検知AI

Anomaly Detection AI Capable of Early-Stage, High-Accuracy Detection of Latent Anomalies in Changing Conditions at Large-Scale Industrial Plants

内藤 晋 NAITO Susumu 田口 安則 TAGUCHI Yasunori 中田 康太 NAKATA Kota

大規模で複雑なプラントでは、設置されている数千点のセンサーから得られる膨大な時系列データを監視し、早期に異常を検知する必要がある。

そこで、東芝は、膨大な時系列データにまたがる複雑な関係を学習することで、プラントの状態変化の中に埋もれ、従来では捉えられなかった異常の兆候を早期検知する異常予兆検知AI「2段階オートエンコーダー」を開発した。この技術を用いて異常を早期に検知することで、異常や劣化の状態に合わせたメンテナンスが可能になり、CBM（状態基準保全）による効率的なプラント運用・保守と稼働率の向上が期待できる。

To facilitate the operation and maintenance of ever more complex large-scale industrial plants, large volumes of time-series data collected from thousands of sensors installed on equipment must be monitored and then evaluated to detect anomalies at an early stage.

Toshiba Corporation has developed a two-stage autoencoder anomaly detection artificial intelligence (AI) capable of detecting any signs of abnormalities hidden in changes in the plant operating conditions at an early stage. Such a task, which has traditionally been difficult, is possible thanks to learning the complex relationships between large volumes of time-series data from various sensors. This makes it possible to conduct maintenance appropriate anomaly and deterioration conditions at an early stage, and is expected to streamline maintenance as well as the improve operational efficiency of large-scale industrial plants through condition-based maintenance (CBM).

1. まえがき

大規模で複雑なプラントでは様々なシステムや機器を監視するために数千点のセンサーが設置されている。プラントを効率的に運用・保守するためには、時々刻々と変化していく膨大なセンサー値を監視し、異常の影響が拡大する前に早期に異常を検知する必要がある。しかし、全てのセンサー値を運転員が常時監視することは困難である。更に、熟練者の高齢化による減少や人手不足の問題もあり、大量のデータを効率的かつ高精度に監視する技術の必要性が高まっている。

また近年、異常を早期に検知するための様々な異常予兆検知AIの開発が進められており、その中でも、大規模で複雑なプラントを扱った際の検知精度の向上が課題となっている。

このような背景と課題の下、東芝は、プラントの状態の変化に伴う、大量のセンサー値にまたがる複雑な関係を学習し、異常の兆候を早期に検知する異常予兆検知AI「2段階オートエンコーダー」(以下、2段階オートエンコーダーと略記)を開発した(図1)。大量のセンサーを同時に扱い、プラントの状態変化の中に埋もれた異常を精度良く検知するのは、このAIが初めて^(注1)となる。



図1. TOSHIBA SPINEX for Energyの異常予兆検知システム

大量のセンサーの時系列データを網羅的に監視し、2段階オートエンコーダーにより異常の兆候を早期に検知する。

Example of trend monitoring display of anomaly detection system

開発したAIによって異常を早期に検知することで、異常や劣化の状態に合わせたメンテナンスを可能にし、CBMによる効率的なプラント運用と稼働率の向上が期待できる。

ここでは、大規模で複雑なプラントの異常兆候を早期に検知する2段階オートエンコーダーについて述べる。また、

(注1) 2021年12月時点、当社調べ。

実運用に付き物である学習データの不十分さに起因した誤検知を、ユーザーがドメイン知識を簡単に2段階オートエンコーダーに与えることで防止する、誤検知低減技術についても述べる。

2. 2段階オートエンコーダー

プラントは複雑なシステムであり、正常に運転しているときも、ポンプや配管などの各機器の温度や圧力などは、プラント全体の状態や各機器の状態など複数の要因が同時に重なり変動する。センサーから得られる値には、こうした複数の要因の影響が大小様々な信号として同時に含まれる。従来技術では、これらの信号の変動を正確に学習できず、ある要因からの信号の異常な変動を、別要因からの信号の正常な変動と誤認し、異常の検知ができない場合がある(図2)。例えば、配管内の流量は、プラントの出力変動やポンプ振動などの影響を受け常に変動しているため、配管の亀裂による流量の微小変動が正常な変動の一部として認識され、異常として検知されないことがあった。

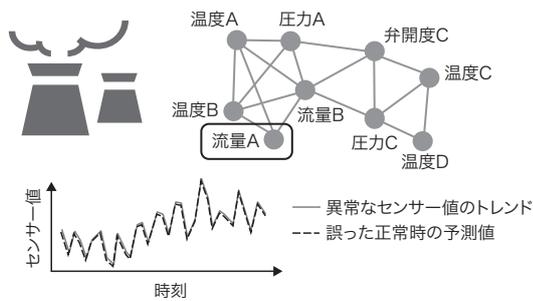
当社は、プラントメーカーとしての知見から、発電や水処理などの動的機器(ポンプなど)を用いて流体を扱うプラントのセンサー値には、二つの主要な信号があることを見いだした(図3)。プラントの運転操作や出力変動などに伴い、多くのセンサーで同時に起きる、比較的振幅が大きくて周期

が緩やかな“大まかな変動”と、ポンプなどの振動や局所的な温度変化などに伴って、少数のセンサーで同時に起きる、比較的小さく速い“微小な変動”である。そこで、大まかな変動と微小な変動という異なる変動から得られる2種類の信号を、各々の変動特性に合わせて設計した二つの深層学習モデル(オートエンコーダー)で学習し、各モデルからの予測値を足し合わせることで、センサー値の正常状態の高精度な予測を実現した(図4)。これにより、センサー値と予測値の差から、センサー値の複雑な変動に埋もれ、従来では捉えられなかった微小な異常変動を検知できる。

この2段階オートエンコーダーを用いて、水処理試験設備の公開データで異常検知を実施した結果、検知精度は従来技術から12%向上し、世界トップレベル(注2)の検知結果が得られた(1)、(2)。この検知性能の向上により、例えば、人が気付くよりも6.8日早い時点で異常の兆候を捉えられるようになる。また、実際のプラントでの例として、図5に火力発電プラントのボイラー燃焼室の異常な温度センサー値のトレンドを示す(3)。異常の兆候時からセンサー値と予測値に差が生じ、異常を早期に検知した。これは、2段階オートエンコーダーの有効性を示すものである。

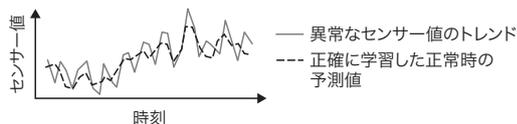
3. 誤検知低減技術

学習データが十分ではない場合、2段階オートエンコーダーは、たまたま同時に変動したセンサー間の、偽の関係



ある要因からの異常変動を、別の要因からの正常変動と誤認して、正常と予測

(a) 従来技術による異常検知の課題



正確に正常変動を学習し予測することで、センサー値と正常時の予測値の差として、異常を検知

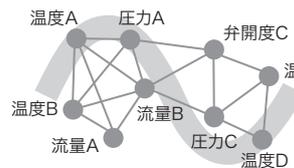
(b) 正確な異常検知

図2. 大規模プラントでの異常予兆検知の課題

多数の機器が連動しているため、センサー値の変動には複雑な関係性があり、それを正確に学習できることが、異常予兆検知の鍵となる。

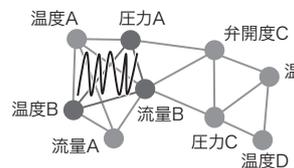
Conventional anomaly detection system issues and measures taken

主要信号1：大まかな変動



多数のセンサーで同時に起きる、振幅が大きくて緩やかな変動
例) 出力変動、運転操作、運転モード変更など

主要信号2：微小な変動



少数のセンサーで同時に起きる、振幅が小さくて速い変動
例) ポンプ脈動、熱交換器での伝熱量の揺れなど

図3. 発電や水処理などのプラントのセンサー値に含まれる二つの主要信号

大まかな変動と微小な変動があり、各々の変動特性に適した二つの深層学習モデルを用いることで、正確に学習できる。

Small and large fluctuations in sensor signals generated at plants such as power generation and water treatment plants

(注2) 2021年12月現在、F1スコア(適合率と再現率を一緒に評価する指標)において、当社調べ。

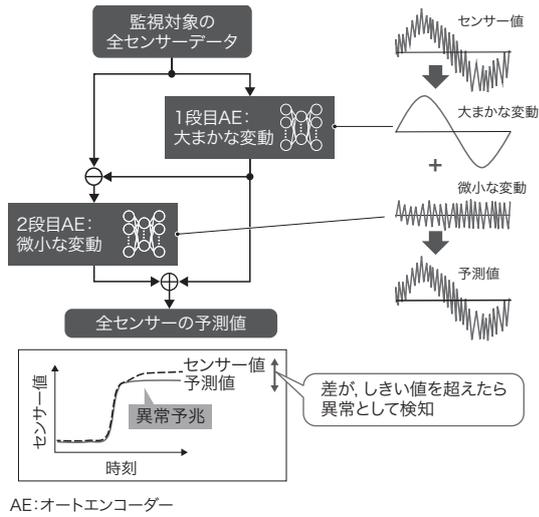


図4. 2段階オートエンコーダーの構成

大まかな変動と微小な変動のそれぞれで最適設計したオートエンコーダーで学習し、予測値を加算することで、高精度な予測を実現した。

Flowchart of operations in architecture of two-stage autoencoder

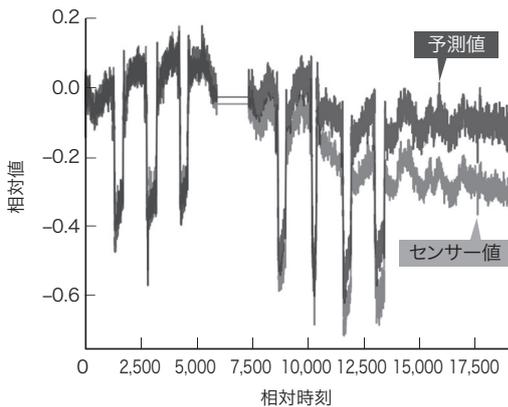


図5. ボイラー系の異常な温度センサー値と2段階オートエンコーダーによる予測値

異常の兆候時からセンサー値と予測値に差が生じ、異常が早期に検知された。

Comparison of anomalous temperature values of boiler system measured by sensor and predicted by two-stage autoencoder

を正しい関係として学習してしまい、誤検知を引き起こす可能性がある(図6)。一方で、現実には十分な学習データを用意できないことが多い。そこで、ユーザーが分かっているセンサー間の関係を、2段階オートエンコーダーの学習に反映できる学習手法を確立した。

この手法では、ユーザーは、監視対象の全センサーについて1対1の細かい関係を与える必要はなく、他のセンサーとの「関係を学習する」又は「関係を学習しない」の2値で手動設定する(図7)。例えば、大規模プラントを、給・復水系やタービン系といったシステム単位で監視する場合、監視対象のシステムの中で、システムの主要な振る舞いに関わるセンサーを「関係を学習する」にし、それ以外を「関係を学習しない」にする。2段階オートエンコーダーは、学習データと「関係を学習」の有無の情報を組み合わせ、細かい関係をより正確に学習する。

この手法の効果の一例として、図8に、図5と同じ火力発電プラントの、ボイラー系におけるセンサー値のトレンドを示す⁽³⁾。図8は、正常なセンサー値のトレンドである。この手法の適用前は、図5の異常と同期してセンサー値と予測値に差が生じ、誤検知が起きていた。このような誤検知は複

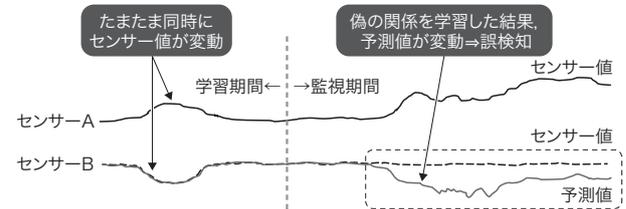


図6. 誤検知発生の様子

センサー間の偽の関係を正しい関係として学習してしまい、予測値が変動する。

Case in which false positive is triggered by learning wrong relationship between sensor data

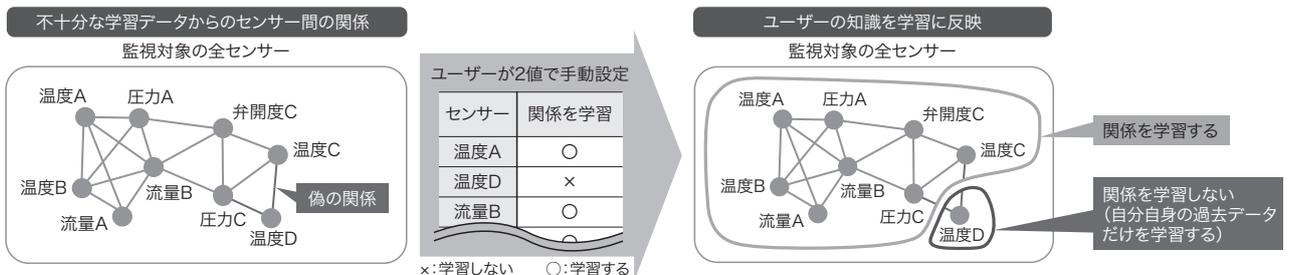


図7. ユーザーの知識を反映する学習方法

ユーザーの知識に基づき、ほかのセンサーとの「関係を学習する」又は「関係を学習しない」の2値で手動設定する。

Training method to implement user knowledge

数のセンサーで発生した。これに対し、適用後はセンサー値と予測値の差がなくなり、これらの誤検知もなくなった。ユーザーは、必要に応じてこの手法を用いることで、十分な誤検知低減の効果が得られる。

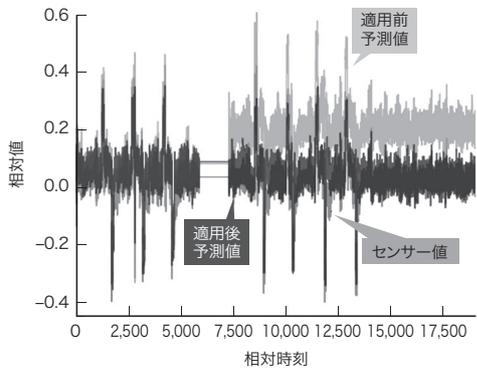


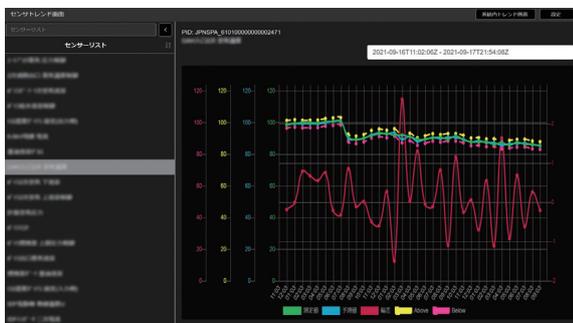
図8. ユーザーの知識を反映する学習手法適用前後の2段階オートエンコーダーによる予測値

適用前は、正常なセンサー値と予測値に差があり誤検知が起きたが、適用後は誤検知が起きなかった。

Comparison of temperature values of boiler system measured by sensor and predicted by two-stage autoencoder before and after application of training method



(a) 発電所外観



(b) 実証試験中の画面

図9. 三川発電所での実証試験

大量のデータをオンラインで監視し、早期に異常を検知できることを実証した。

Demonstration tests at Mikawa Power Plant

4. あとがき

2段階オートエンコーダーを用いた異常予兆検知システムは、東芝エネルギーシステムズ(株)の子会社の(株)シグマパワー有明が運営する三川発電所で実証試験(2020～2022年)を行い、大量のデータをオンラインで監視し、早期に異常を検知できることを実証した(図9)。現在、この2段階オートエンコーダーは、電力事業者や製造業向けのデジタルサービス“TOSHIBA SPINEX for Energy”のソフトウェア部品として組み込まれており、クラウドサービスとオンプレミスの両方で提供可能である。

文献

- (1) Naito, S. et al. "Anomaly Detection for Multivariate Time Series on Large-Scale Fluid Handling Plant using Two-Stage Autoencoder". Proceedings of 2021 International Conference on Data Mining Workshops (ICDMW 2021). Virtual, 2021-12, IEEE, 2022, p.542-551.
- (2) Naito, S. et al. "Anomaly Detection AI Technology, Two-stage Autoencoder". Fifth International Conference on Nuclear Power Plant Life Management (5th PLiM). Vienna, Austria, 2022-12, IAEA, 2022, Paper No.17.
- (3) 田口安則, ほか. 2段階オートエンコーダの発電所データでの異常予兆検知性能評価. 保全学. 2024, 23, 1, p.97-102.



内藤 晋 NAITO Susumu, Ph.D.

研究開発センター 知能化システム研究所 アナリティクスAIラボラトリー
博士(理学) 日本原子力学会・日本保全学会・日本物理学会・応用物理学会会員
Analytics AI Lab.



田口 安則 TAGUCHI Yasunori

研究開発センター 知能化システム研究所
アナリティクスAIラボラトリー
電子情報通信学会・日本保全学会会員
Analytics AI Lab.



中田 康太 NAKATA Kota, Ph.D.

研究開発センター 知能化システム研究所
アナリティクスAIラボラトリー
博士(理学) 人工知能学会会員
Analytics AI Lab.