

[スマートファクトリーは工場の何を変えるのか?]

② リアルタイム AI 技術の製造業への適用



櫻井保志 大阪大学 産業科学研究所



製造業 DX のためのデータストリーム解析

製造業におけるデジタルツインやデジタルトランスフォーメーション、自動車分野のコネクティッドカー・サービス、デバイスや材料開発におけるマテリアルズインフォマティクスなど、産業や社会は大きく変化し、このような状況において AI やビッグデータ解析は第 4 次産業革命を支える技術として期待されている。その中でも AI 関連の技術については深層学習を用いたソフトウェアの開発が活発になっており、製造業、自動車、金融、医療・ヘルスケア、小売業など広範囲に渡る事業に活用されている。深層学習による AI 実用に関しては基本的なアプローチとして、自然言語処理による文書解析や対話サービス、画像処理に基づく判別処理などの課題に対して、大量のデータから 1 つの予測モデルを学習し、その固定的なモデルから解析処理を行うような取り組みが主流である。

一方、これから本格的に到来するデータ駆動型社会においては IT、IoT などによりさまざまな端末やセンサからデータを収集することになるが、Beyond 5G 時代においては通信環境がきわめて充実し、大容量・高速・低遅延・多点同時接続の通信が実現するとともに、次世代 IoT 技術の進化に伴いデータ量は爆発的に増大する。ネットワークから大量に流れてくるビッグデータ、すなわちデータストリームには、刻々と変化する環境や突発的な外的要因の影響などにより、時間とともに変わり、時には急激に変化する時系列情報が含まれて

いる^{★1}。実社会において多種多様な設備やデバイスから発生する IoT データストリームには、設備やデバイスに共通する特徴を含む場合もあれば、個体差を示すこともあり、さらにさまざまな状況において発生する事象間の関係性や因果関係なども含んでいる。そのため、データストリーム解析においてはモデルを固定することなく、時系列パターンの急激な変動や設備個別の特徴や傾向の変化を高速に検出し、モデル学習やモデル更新をリアルタイムに処理することが重要であり、このような新しい課題に対応することが、製造業をはじめとする事業の成否を左右する大きな鍵となる。

製造業と IoT を巡る環境が急速に変化し、生産性、品質向上、省エネルギー化のためのスマート工場に関する技術開発は必要不可欠になっている。スマート工場の実現は、設備から稼働状態などの情報をリアルタイムに収集し、人の指示を介さず自律的に判断し、工程を効率化/最適化して、より優れた製品を創出する。特に近年、サイバー空間上に実際の製品や製造工程を再現してリアルタイムに現実世界と連動させようとするデジタルツインに関する取り組みが注目されている。ただ現状、シミュレーションを通して 3 次元データで製品の特性をテストするなど、生産のリードタイムの短縮にとどまっている。物理法則に沿った数式として表現できるタスクではシミュレーションツール

★1 データストリームの基礎技術については、有村博紀、喜田拓也：データストリームのためのマイニング技術，情報処理，Vol.46，No.1，pp.4-11 (Jan. 2005)，櫻井保志：時系列データのためのストリームマイニング技術，情報処理，Vol.47，No.7，pp.755-761 (July 2006) を参照。

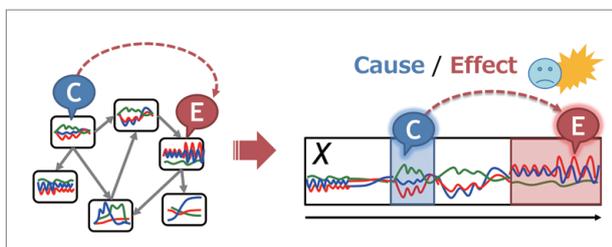
特集
Special Feature

が使えるものの、大規模な製造システムの稼働状況を解析するようなタスクを想定した場合、多数の設備の動作状況や周辺環境が複雑に影響し合い、それら影響の度合いや因果関係が自明ではないため、シミュレーションツールによって課題を解決することは難しい。そこで、生産工程における設備稼働データを統合的に解析し、製造工程を効率化し、リアルタイムに最適化するような高度な AI ソフトウェアが求められている。

本稿では、筆者らがリアルタイム AI 技術と呼んでいる、IoT ビッグデータを高速に学習し、予測、要因分析、トラブル予知、行動最適化のための情報提供をリアルタイムに行う AI 技術基盤について述べる。その中でも特に 3 種類の要素技術、(1) リアルタイム予測と動的要因分析、(2) リアルタイム時系列テンソル解析、(3) リアルタイム特徴自動抽出、について概説する。また、実際の工場の生産ライン支援や自動車運行管理など、製造業 DX に関連する取り組みを実例とともに紹介する。

リアルタイム予測と動的要因分析

図-1 と図-2 はリアルタイム将来予測・動的要因分析技術¹⁾²⁾の概要を示している。IoT/ センサデータストリームをはじめとする大規模な時系列データから、リアルタイムに特徴や潜在的なトレンド(レジーム)を検出し、各レジーム間の動的な関係性を見つけることにより、長期的かつ継続的に時系列イベントストリーム内の重要な動的要因を監視し、将来のイベント予測を行う。



■ 図-1 時系列データストリームにおける動的関係(要因-結果)の解析の様子

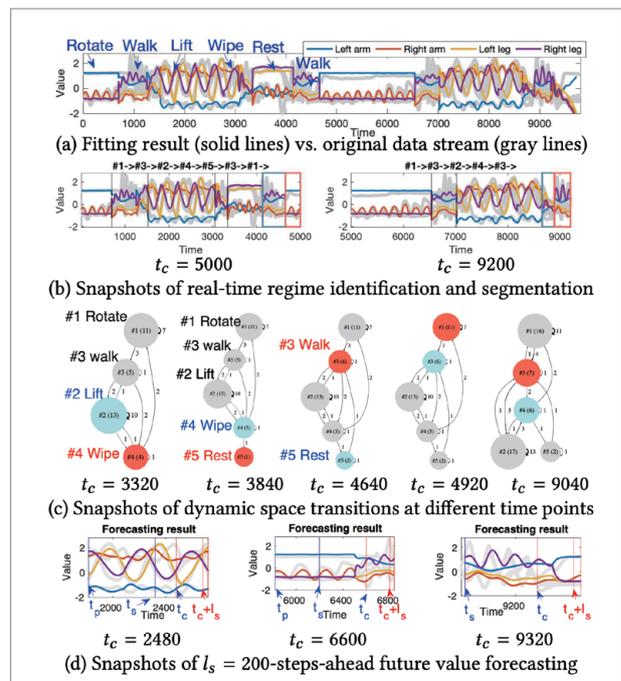
データストリームのためのリアルタイム予測と動的要因分析

開発技術は次の 3 つの特長を有する。

非線形動的システムに基づくリアルタイム学習: 実世界における時系列データストリームは、さまざまな時系列パターンから構成され、外的要因などによって突発的に変化していく。本技術はデータストリームの最新時刻の潜在的トレンドや時系列パターンを動的に把握、モデル化し、将来値を継続的に予測し続ける。特に、さまざまな時系列ダイナミクスを非線形動的システムによって表現するとともに、時系列トレンドの急激な変化を変化点としてリアルタイムに検出し、モデルパラメータを瞬時に切り替え、柔軟に予測を行う。

アルゴリズムとしては、まずデータストリームから学習したさまざまな非線形方程式のモデルをデータベース(モデル DB)に格納する。予測処理においては、現在の時系列パターンに合うモデルを DB から探索し、探索したモデルを用いて予測値を推定する。

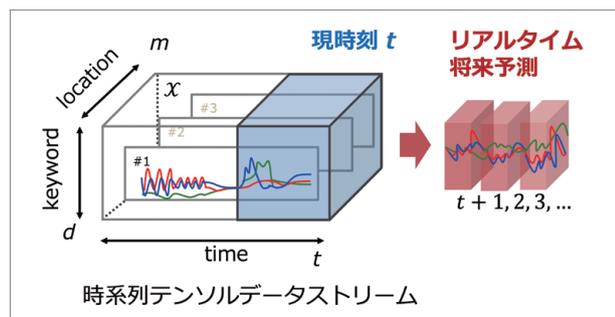
動的要因分析: 一般に、大規模な時系列データストリームは、自然現象や人々の社会活動、さらにはさまざま



■ 図-2 リアルタイム要因分析・将来予測技術

な設備の動作状況など、さまざまな事象を表現している。本技術は、時系列ビッグデータから時系列モデル間の前後関係（要因－結果関係）を捉え、それらの事象の連鎖を動的空間遷移ネットワークとしてモデル化する。さらに、要因分析と動的空間遷移ネットワークを用いることにより、予測精度を向上させている。図-2は本技術を用いたリアルタイム要因分析の出力例である。ここでは、加速度センサデータを用いて解析している。より具体的には、工場における作業者の両手足4カ所に加速度センサを設置し、100Hz（ヘルツ）で加速度を計測している。図-2(a)は、オリジナルのデータストリームの学習結果を示し、図-2(b)は、各時刻におけるリアルタイムパターン検出とモデル生成、図-2(c)は各時刻におけるネットワークの成長の様子を示す。より具体的には、作業者の行動の間のつながり（回転する→歩く→持ち上げるなど）をネットワークとして示している。図-2(d)は、学習した動的モデルとネットワークを用いたリアルタイムの様子を示している。ここでは、200単位時刻先（つまり、2秒先）の行動を予測している。現時刻 t_c において、時刻 t_c+l_s を予測している。ここで、 l_s は予測する長さを示す。本技術によってリアルタイム要因分析を実現することができ、たとえば、スマート工場における装置故障、自動車走行における急ブレーキや急なハンドル操作など、さまざまな事故やトラブルの兆候（サイン）をビッグデータから高速かつ自動的に抽出することが可能となる。

リアルタイム行動支援: 本技術は要因分析と予測に基づいてさまざまな状況を引き起こす要因を検出するこ



■図-3 リアルタイム時系列テンソル解析

とで、リアルタイムに最適な行動を選択、推薦情報として提示する。技術の応用先としては、スマート工場、すなわち製造業の設計製造設備の高度化、さらには建設現場や車両運転における事故の防止など多岐にわたり、生体データや視線データを用いた介護やヘルスケアのサポートにも有効な技術である。

リアルタイム時系列テンソル解析

リアルタイム時系列テンソル解析技術³⁾は、リアルタイム予測技術^{1) 2)}をベースに、テンソル解析技術として発展させることによって開発された基礎技術であり、図-3は、複合データストリームの時系列テンソル解析、特にリアルタイム将来予測の様子を示している。本技術は、現時刻 t における動的パターン（図-3青色箇所）を解析することにより、将来発生するイベント（図-3赤色箇所）をリアルタイムに予測し続ける。ここでの例は、オンライン活動データを用いているが、本技術は、オンライン活動データにとどまらず、製造業における生産工程の設備データなど、さまざまな複合時系列ビッグデータストリームのリアルタイム解析・予測に適用することが可能である。

図-4は、Web上におけるキーワードアクセス件数推移データに対し本技術を適用した例を示している。時間、地域、キーワードのように複数の属性を持つテンソルデータストリームが与えられたとき、最新の観測データ（図-4(a)青）を監視しながら潜在的なトレンドを発見し、適応的にモデルを変化させながら長期先のデータ（図-4(a)赤）を予測し続ける。このとき、図-4(b)のように各地域で共通する周期(季節)パターンを抽出し、それらに基づき、図-4(c)に示すように類似パターンを有する地域のグループ化を行う。このように本技術は、非線形微分方程式に基づき、非線形性を有する時系列ダイナミクス、長期トレンド、周期性を同一のモデル空間で表現し、そして時系列テンソルの内部において類似した潜在トレンドを持つ属性データのグループ化を自動的かつ効率的に行う。

リアルタイム特徴自動抽出

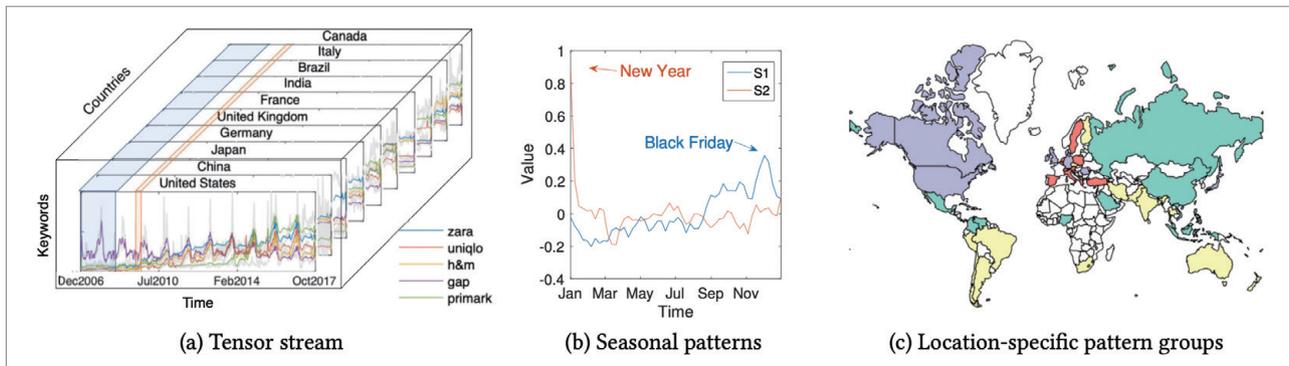
リアルタイム特徴自動抽出技術^{4), 5)}は、大規模時系列データストリームに含まれる典型的なパターンを発見するための技術であり、**図-5**は技術の概要を示している。与えられたデータストリームをリアルタイムに解析し、時系列パターンの種類と変化点を発見し、それらの特徴をモデルパラメータとして表現する。

特徴自動抽出：大規模データストリームの解析には高度なマイニングアルゴリズムが求められるが、複雑な演算による計算コストに加えて高度なパラメータチューニングなどによる時間的・人的コストが高くなり、実用化の際にはそれらが大きなボトルネックとなる。本技術では符号化理論に基づくモデル評価基準を応用し、解析データに関する事前知識を必要とせず、データの要約情報（時系列パターンの種類・変化点）を自動的に取得する。より具体的には、時系列シーケンスの符号化コストとコスト関数を定義し、コスト関数を最小化するようなモデル数、セグメント分

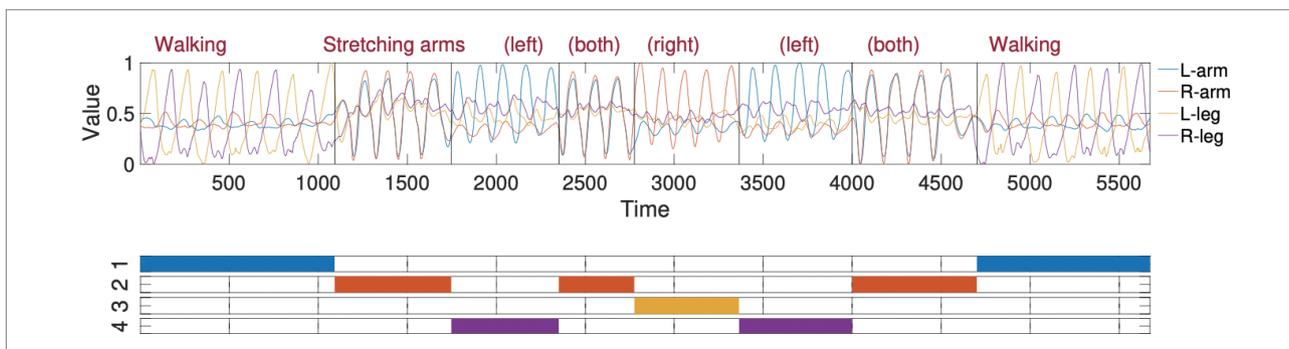
割や割り当て、モデルパラメータを推定することにより、時系列データの特徴を自動抽出する。

図-5は本技術を用いたリアルタイム解析の出力例である。**図-5**上段はヒトの両手足4カ所に加速度センサを設置し、歩行と3種類（両腕、右腕、左腕）のストレッチで構成される合計4種類の動作を捉えたデータストリームを示す。**図-5**下段の番号は、本技術が検出したパターンのIDを示し、長方形の両端は各パターンの開始点・終了点を示す。本技術はセンサデータをリアルタイムに監視し、歩行、両腕のストレッチ、と次々にパターンの変化点を検出する。このとき、モデル評価基準を用いて新たなモデル生成の必要性を自律的に判断することにより、パターンの種類（モデルの数）を自動的に決定する。**図-5**に示すように、本技術は8つのパターン変化点を検出し、それらを4つの動作へと分類することに成功している。

高速パターン検出：本技術は階層構造を有する確率モデルを用いて過去に検出したパターンの特徴を表現し、新たなデータが観測されるたびに類似パターンの



■ 図-4 複合ビッグデータストリームのためのリアルタイム解析技術



■ 図-5 モーションキャプチャデータストリームに対するリアルタイム特徴自動抽出技術の出力結果

検索とモデルパラメータの推定を逐次的に行う。このとき、最後に観測したパターンのデータと過去に推定したモデルパラメータのみを保持するため、一度に大量のデータを処理する必要がなく効率的にデータストリームを処理することができる。

データストリーム解析技術の産業への展開

多角的テンソル特徴抽出技術の車両走行データ解析への応用

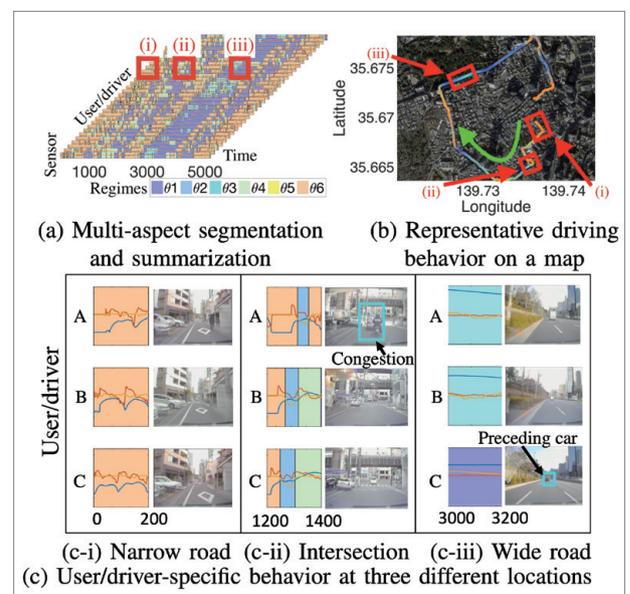
筆者らの研究グループではトヨタ自動車と連携し、多角的テンソル特徴抽出技術⁶⁾を共同開発した。運転行動の予測に基づく走行支援サービスの実現に向けて、本プロジェクトでは各ロケーションにおけるドライバ共通の運転パターンやドライバの個人差を把握し、モデルとして学習/表現するための要素技術を開発することを目的としている。開発技術はデータに含まれる重要なパターンの時間遷移やユーザ特性を自動的に抽出する。センサ、ユーザ、時間など複数ドメインで構成される時系列テンソルデータから各ドメインにまたがる複雑な特徴を時系列パターンとして検出し、各パターンをモデルパラメータとして要約する。

多角的特徴抽出：実社会において収集されるビッグデータは、センサ、デバイス、ユーザ、時間など複数のドメインを持つ時系列テンソルデータとして表現でき、本技術は、時系列テンソルに含まれる複雑な特徴を多角的に解析し、パターンの時間遷移とドメイン間の個体差を同時に抽出する。図-6は車両走行データの解析結果である。図-6(a)は(センサ、ドライバー、時間)で構成される時系列テンソルからのパターン抽出結果であり、同色のセグメントが類似パターンのグループを表している。図-6(b)は、出力結果を実際に走ったコース上にプロットしたものであり、図-6(c)では詳細な出力結果を示している。本技術は、直進、右左折、徐行など車両走行における運転行動の時間遷移のみならず、ドライバごとの特性も同時に解析し、

車両走行のさまざまな共通パターンを抽出すると同時に、車両走行のグループ化と、モデル化を完全自動で行う。

社会実装のための事業化に向けての取り組み

筆者らの研究グループでは、さまざまな企業と連携し、社会実装に向けて製造業 DX 技術の実用化に取り組んでいる。その中でも本稿ではソニーセミコンダクタマニュファクチャリングとの取り組みを紹介する。**半導体製造工程における設備故障予測：**上述した要素技術を統合、発展させ、複合時系列データからイベント予測を行うための AI ソフトウェアを開発した。センサデータの潜在的な動的パターンを時系列モデルとして要約し、特徴量として抽出することにより、イベントの要因分析を行いながら長期先のイベントの発生確率を予測することを可能とする。開発したソフトウェアを活用して、CMOS イメージセンサの半導体製造工程における DRY 装置のターボ分子ポンプの故障予測に関する評価実験を行っている。DRY 装置のターボ分子ポンプの突発故障は製造ラインへの影響が大きく、また高額パーツのライフ適正化を進めることも可能となるため、故障予測のニーズはきわめて高い。



■ 図-6 車両走行データに対する多角的テンソル特徴抽出技術の出力結果

特集 Special Feature

開発ソフトウェアによって、DRY 装置のターボ分子ポンプ故障を事前に予測し、計画保全を実現する。

図-7は、コントロールユニットにおける管理データ(軸の正常位置からのブレ、電流値、回転数など)およびターボ分子ポンプの振動計測データを解析し、装置状態を推定した結果である。図-7の上段はオリジナルの入力情報となる22次元の設備管理および稼働データであり、最右端の時系列データの切れ目において故障が発生している。開発ソフトウェアは、センサデータに潜在する特徴的パターンやその変化点を時系列として捉え、装置状態を推定しており、図-7下段はその解析結果である。装置状態を正常(青)、注意(オレンジ)、水色(故障直前)に分類しており、水色のセグメント幅は約13日である。すなわち、開発したソフトウェアによって、約13日前に故障の兆候を検出している。評価実験では、故障データは5件しかないものの、5件すべての故障の兆候を完璧に捉え、最短でも8日前に、最長で15日前に設備故障の予測に成功している。

革新的な AI 生産プラットフォームの開発に向けて

本稿では、最近のデータストリーム解析技術と製造業DXへの応用について述べた。日本において製造業はGDPの22%を占め、今も日本経済を支える重要な産業である。そして、日本が組込・制御機器分野で強みがある点に鑑みれば、その技術や製品の価値を

高めるためにIoTビッグデータをリアルタイムに解析する技術はきわめて重要となる。

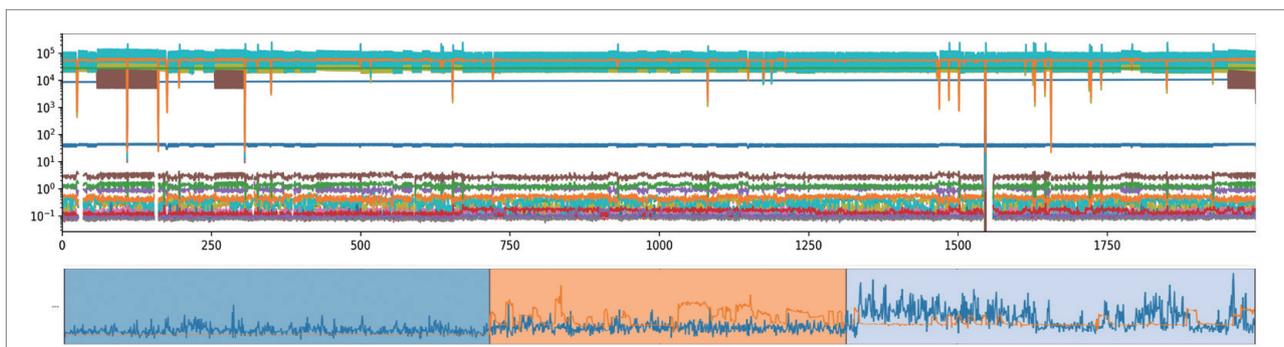
今後の製造業においては、Beyond 5G/6Gの技術を活用して設備を連携させ、消費者/利用者個々のニーズにフィットさせる多品種少量生産の取り組みも必要となるため、性能、機能、計算速度を劇的に向上させたAIソフトウェアは、設計から製造、保守まで、製造システム全体を変革するキーテクノロジーになる可能性を秘めている。

参考文献

- 1) Matsubara, Y. and Sakurai, Y. : Regime Shifts in Streams: Real-time Forecasting of Co-evolving Time Sequences, ACM SIGKDD Conference (KDD), pp.1045-1054 (Aug. 2016).
- 2) Matsubara, Y., and Sakurai, Y. : Dynamic Modeling and Forecasting of Time-evolving Data Streams, ACM SIGKDD Conference (KDD), pp.458-468 (Aug. 2019).
- 3) Kawabata, K., Matsubara, Y., Honda, T. and Sakurai, Y. : Non-Linear Mining of Social Activities in Tensor Streams, ACM SIGKDD Conference (KDD), pp.2093-2102 (Aug. 2020).
- 4) Matsubara, Y., Sakurai, Y. and Faloutsos, C. : AutoPlait: Automatic Mining of Co-evolving Time Sequences, ACM SIGMOD Conference, pp.193-204 (June 2014).
- 5) Kawabata, K., Matsubara, Y. and Sakurai, Y. : Automatic Sequential Pattern Mining in Data Streams, ACM Int. Conf. Information and Knowledge Management (CIKM), pp.1733-1742 (Nov. 2019).
- 6) Honda, T., Matsubara, Y., Neyama, R., Abe, M. and Sakurai, Y. : Multi-Aspect Mining of Complex Sensor Sequences, IEEE Int. Conf. on Data Mining (ICDM), pp.299-308 (Nov. 2019).
(2021年12月5日受付)

■櫻井保志(正会員) yasushi@sanken.osaka-u.ac.jp

1991年同志社大学工学部卒業、同年NTT入社。1999年奈良先端科学技術大学院大学博士課程修了。工学博士。NTT研究所、熊本大学を経て、2019年より現職。ACM KDD best paper awards (2008年、2010年)など受賞。AI・IoTデータストリーム処理、Webや医療情報解析の研究に従事。



■図-7 設備稼働データの解析と故障予測