生産装置の異常検知のためのエッジ分析技術

Edge-based Analytics for Detecting Anomalies in Manufacturing Equipment

中林 暁男 *1
Akio Nakabayashi

IoT（Internet of Things）技術が，システム上から見えていなかった各生産要素のデータを利用可能にし，AI技術が得られたデータの解析を行うことで，生産改善のポイントの特定や異常検知など，熟練者が行ってきたタスクの代替を実現し始めている。しかし，生産における多くの情報インフラはこうした状況を予期して設計されておらず，大量に存在するデータの活用が困難なケースがしばしば見られる。YOKOGAWAでは，そのようなユーザニーズをいち早く捉え，エッジコンピューティングによるソリューション開発を進めてきた。エッジコンピューティングを用いれば，エッジ（装置のすぐそばという意味）にて，収集したデータの解析を行い，その解析結果を上位系へと転送するしくみを構成し，既設インフラを最大限活用しながらIoT/AI導入を進めることができる。本稿では，その成果の1つである異常検知向けアプリケーションの技術的な要点を紹介する。

The Internet of Things (IoT) technology enables the use of various data from manufacturing equipment, which used not to be possible with existing manufacturing execution systems. AI technology can help experts to execute their tasks by analyzing such data and identifying points to be improved or detecting anomalies in equipment for improving availability. However, most of the information infrastructure is not designed for the IoT and AI, and thus large amounts of informative data are not fully used. Yokogawa has therefore developed edge-based solutions that use computers near manufacturing equipment, in order to solve customer needs. While making full use of existing manufacturing execution systems, these solutions enable the construction of an IoT/AI system that analyzes data acquired in the field and transmits the analysis results to upper-level systems. This paper describes the technical points of Yokogawa's edge computing system that can detect anomalies in manufacturing equipment.

1. はじめに

近年，製造業の現場は，国際競争環境が激化する中で，品質向上／コスト削減への圧力の増大など，生産上の大きな課題に直面している。一方で，ベテラン技術者の勇退が進んでおり，現場力の低下に不安を覚える声も多い。この状況に対して，IoT（Internet of Things）やAI／機械学習／統計等の解析技術の活用によるオペレーションの変革が望まれている。IoT技術はシステム上には見えていなかった各生産要素の情報（装置の詳細な工程データなど）を統合して，利用することを可能にしてきた。またAI技術は，生産改善のポイントの特定や異常検知などの熟練者が行ってきたタスクの代替を実現し始めている。しかし，生産における多くの情報インフラはこうした状況を予期して設計されていない。その結果，例えば機械系装置の振動など大量になる傾向があるセンサデータを，既設のインフラで収集することが困難なケースは多くの現場で見られる。

このような状況に対応するため，近年はエッジ（装置のすぐそばという意味）において，ある程度の解析を行い，その解析結果を上位系へと転送するようなエッジコンピューティングを活用する方式が採用され始めている。エッジコンピューティングにより，リソースに制限があるデータインフラ上で，大量のデータの分析を行うことが可能になる。

YOKOGAWAではそのようなトレンドをいち早く捉え，ユーザからのニーズも大きい設備管理タスクの支援をファーストターゲットとして，エッジコンピューティングソリューションの開発を進めてきた[(1)]。2018年6月にはDUCSOnEXとして，横河ソリューションサービスより生産設備の異常検知を行うパッケージの販売も開始している。

*1 マーケティング本部 イノベーションセンター
インキュベーション部

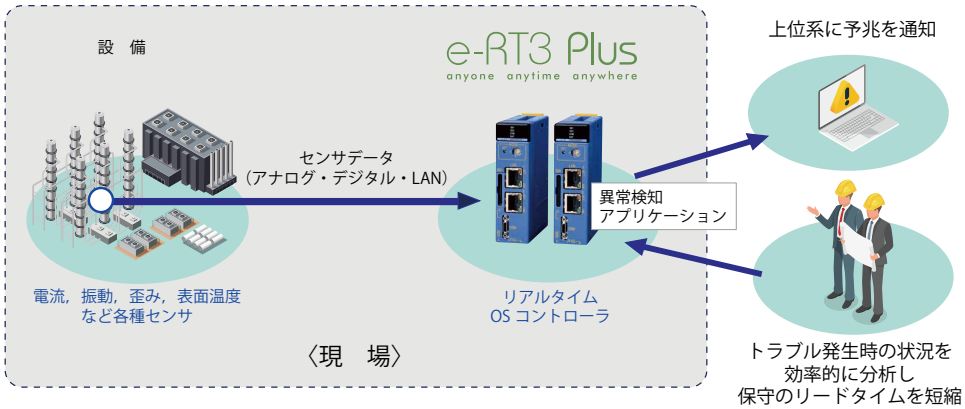

図 1 バッチ分析とオンライン分析の概念図

本稿では，この YOKOGAWA が提供する異常検知向けエッうジコンピューティングソリューションの技術的なバックグラウンドを示し，その要点を紹介する。

2. エッジコンピューティングによる異常検知ソリューションを実現するシステム

2.1 システム全体のアーキテクチャ

図 1 に，エッジコンピューティングによる異常検知ソリューション実現のためのシステムアーキテクチャを示す。ソリューションの核となるのは，e-RT3 Plus と同ハードウェア上に実装された異常検知アプリケーションである。e-RT3 Plus には，生産装置の状態を計測するための各種センサが接続可能である。異常検知アプリケーションに組み込まれたエッジ分析モジュールが，センサ値に対する非正常度などの解析値を計算することになる。非正常度は，データの正常性を確認するための指標であり，３章にて詳述する。e-RT3 Plus は LAN のインタフェースも備えており，算出された解析値は各種通信プロトコルにより，上位系に転送される形態が一般的な構成である。

2.2 異常検知アプリケーションの構成

生産装置の異常検知に用いる物理量は，振動や電流などのように高いサンプリングレートで見なければ意味がないデータが多い。近年は，深層学習技術などの進展により，こうした情報量の多い生のデータをそのまま分析することが可能となってきている。しかし，エッジに置かれる機器の計算リソースは十分ではないことが多く，エッジでの実装は困難である。また，エッジではメモリ／ストレージの面からの制約も大きい。一般に，異常検知のための解析ではベースとなる基準データ（学習データとも呼ぶ）を蓄積した上で，同データに対してバッチ（一括処理）的な解析処理を施し，パターン学習を行う必要がある。しかし，エッジではメモリ／ストレージのリソース制約から学習データの蓄積が困難なため，そのような分析手法が適用できない場合がある。そこで，我々は「解析対象データの絞り込み」，「センサデータからの特徴抽出」，「データを蓄積しないオンラインパターン学習」という３つのアプローチにより，異常検知アプリケーションを実現している。**図 2** にその論理構成を示す。

セグメント抽出ブロックは，サンプリングされたセンサデータの特定の時系列上の区間をセグメントデータとして切り出すことで，解析対象データの絞り込みを行う役割を持つ。例えば，連続的に稼働する装置の場合には，一定間隔／一定期間をセグメントとしてデータを抽出することが考えられる。また，機械加工系の装置などでは，バッチ的に処理を行っている時系列上の区間を，制御信

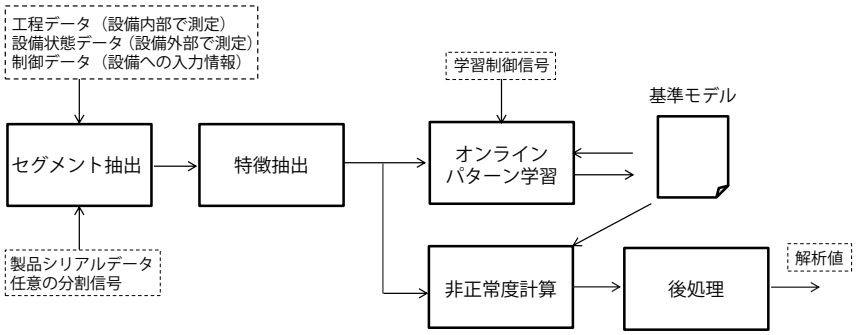

図 2 異常検知アプリケーションの詳細構成

号を基にデータを切り出すなどの構成が考えられる。

特徴抽出ブロックは，セグメントデータ全体を，セグメントデータの傾向を表すいくつかの特徴値（以下，特徴ベクトルと呼ぶ）に変換することで，データ量の削減を行う役割を持つ。また，特徴ベクトルに変換することで，バッチ工程における処理時間，すなわちデータ長の不定さや，データ収集開始タイミングのズレによる位相差の問題などにも対処できるようになる。

DUCSOnEX では，製造業において解析サービス，コンサルティングを提供してきた YOKOGAWA の経験を基に，実用性を確認した６種の特徴抽出法を用意している。例えば，基本的な統計量を基にした特徴抽出や，FFT（周波数解析）を基にした特徴抽出である。これらの特徴抽出法を組み合わせることで多様な装置への対応が可能となる。**図 3** は基本的な統計量の場合の例であり，平均値，標準偏差，最小値，最大値により特徴ベクトルを構成している。

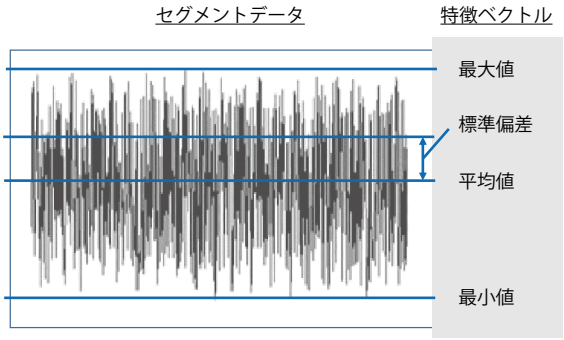

図 3 特徴抽出の例

オンラインパターン学習ブロックは，前段で算出された特徴ベクトルのパターンを，１つの特徴ベクトルを得るごとに逐次的に学習し，特徴ベクトルに関するモデルを生成する役割を持つ。学習は，アプリケーションユーザが明示的に指示したタイミングのみで行う。その詳細については，３章で述べる。

非正常度計算ブロックは，学習信号が与えられていない場合，特徴ベクトルを学習せずに，前述のモデルに対する新たに入力された特徴ベクトルのズレの大きさを定量的に計算する役割を持つ。このズレを，非正常度と呼んでいる。非正常度が大きいほど，今までとは異なる特徴ベクトル≒セグメントデータであることを表しており，設備の観測結果が変化していることを示すものである。

最後に，後処理ブロックは，非正常度などの解析値にフィルタをかけることにより，センシングに伴うノイズ（外乱などによる変動も含む）を低減する役割を持つ。

以上の処理を行うエッジコンピューティングプラットフォーム用に最適化したプログラムを開発し，それらの各要素が連動することで，異常検知アプリケーションを実現している。

3. オンラインパターン学習に基づく異常検知法

異常検知の核となる解析は，正常と見なせるデータセットに対するパターン＝モデルの学習である。本章では，まず従来から多くの産業用アプリケーションでも用いられているバッチ型のパターン学習と同結果に基づく異常検知を述べ，次に，DUCSOnEX でも採用しているオンライン（逐次処理）型のパターン学習について述べる。

3.1 バッチ型のパターン学習／異常検知

図 4 は，前述の特徴ベクトルを２次元 [x_1 x_2] とした場合の学習用データセットの例である。

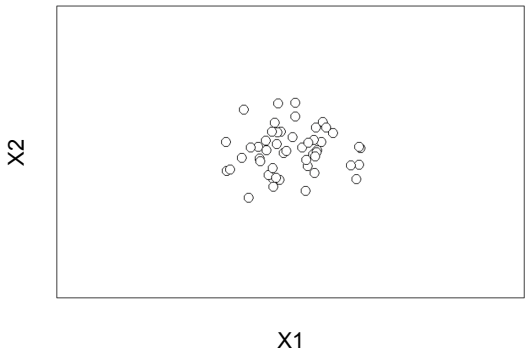

図 4 データ例

実際には対象によるが，特徴ベクトルは数十から数千次元のデータであることに注意いただきたい。統計的観点からは，パターン学習とはこのデータセットを用いてデータサンプルの発生確率を求める関数，すなわちデータに対する確率モデルを推定することである。

例えば，簡単な確率モデルとして，特徴ベクトルの発生に関する正規性の仮定と特徴ベクトルの要素間の独立性の仮定から，次のモデルを構成することができる。

$$p(x_1, x_2) = N(x_1|\mu_1, s_1^2)N(x_2|\mu_2, s_2^2) \qquad (1)$$

N は正規分布の確率密度関数を表し，μ，s はそれぞれ平均，標準偏差パラメータを表す。このモデルをベースとしたパターン学習とは，２つの正規分布のパラメータである平均値と標準偏差を推定することであり，通常，次のように算出される。

$$\mu_i = \frac{1}{T}\sum_t x_{t,i}\,,\ s_i^2 = \frac{\mathrm{T}}{\mathrm{T}-1}\left\{\frac{1}{\mathrm{T}}\sum_t x_{t,i}^2 - \mu_i^2\right\},\ \mathrm{i} = 1,2 \qquad (2)$$

t はサンプル番号を表し，T は特徴ベクトルのサンプル数である。ここで，総和演算の中で全てのサンプルが参照されており，全サンプルに対する一括処理にてパラメータが推定されていることに注意する。

このような確率モデルは，与えられた学習用データセットを基にパラメータを推定することで，任意の特徴ベクトルに対する確率密度を示している。すなわち，データが存在すると思われる領域では高い値を，データが存在しないと思われる領域では低い値を返す関数となる。

この確率値をデータの正常性に対応させ，異常検知を行う。すなわち，モデルから見たデータの非正常度を，次のように定義し利用する。

$$\text{非正常度} \quad \propto -\ln p(x_1, x_2) \tag{3}$$

図 4 のデータを基にして推定されたモデルに対する非正常度のカラーマップを，**図 5** に示す。

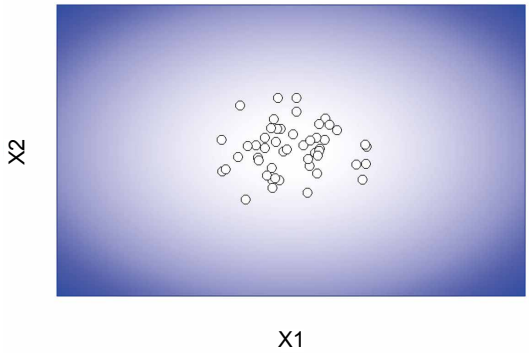

図 5 確率モデルによる非正常度の計算例

式（3）の値が高い点は濃色，低い値は淡色で表示している。**図 5** からデータ群から離れるほど，大きな非正常度が得られていることが分かる。

以上が，特徴ベクトルの学習用セットが与えられた場合における，パターン学習から異常検知への流れである。ここで，前述のように，エッジ実装における本質的な課題の 1 つは，元となるデータの蓄積が困難な場合があるということである。この動機から，我々はバッチ型パターン学習ではなく，次節で述べるオンライン型パターン学習アルゴリズムを採用した。

3.2 オンライン型のパターン学習

式（2）の総和計算において，全サンプルにわたっての計算が行われ，その結果，各正規分布のパラメータが算出されている。このような確率モデルを推定するために必要なデータに関する計算値は，確率モデルの十分統計量と呼ばれている。

ここで，サンプル 1, … , T に対する十分統計量は，次のように再帰的に計算することが可能である。

$$\begin{aligned} x_{sum,t} &= x_{sum,t-1} + x_t, \quad x_{sum,0} = 0 \\ x^2_{sum,t} &= x^2_{sum,t-1} + x^2_t, \quad x^2_{sum,0} = 0 \end{aligned} \tag{4}$$

ここで，$x_{sum,\,t}$, $x^2_{sum,\,t}$ はそれぞれ時点 t におけるデータベクトルの総和と平方和を表す。すなわち，t 番目のサンプルを得たときの十分統計量を計算するのに必要な情報は，t-1 番目の十分統計量と，t 番目のサンプルだけである。さらに，この更新式による T 番目までの十分統計量の計算結果は，式（2）で算出している結果と同一である。

このことから，十分統計量をデータの代わりに保存しておくことで，全特徴ベクトルのサンプルを保持することなく，1 サンプルずつの提示により，パターン学習を行うことができる。十分統計量を更新した後には，学習に用いた特徴ベクトルは捨ててよい。DUCSOnEX では，この考え方に基づいた 3 種類のパターン学習手法を，オンラインアルゴリズムとして実装している。

4. おわりに

本稿では，YOKOGAWA が提供するエッジ型異常検知システムに関して，その核となるしくみについての概説を行った。

近年の IoT 化の進展は，生産システムがハンドリングしなければならないデータ量を加速度的に増大させている。これらのデータを全て集約し，解析を行うことが理想形ではあるが，初期段階ではその投資効果は不明瞭なため，このようなデータを扱うための情報インフラへの追加投資は正当化されにくい。本稿で述べたようなエッジコンピューティング技術を利用することにより，既設情報インフラを活用しつつ，IoT ソリューションの軽量かつ迅速な立ち上げを行うことができる。YOKOGAWA では，エッジ分析技術のさらなる可能性を模索し，研究開発を進めている。

参考文献

(1) 白井呂尚，中林暁男，“エッジコンピューティングによる設備異常予兆監視ソリューション”，計装，Vol. 60，No. 3，2017，p.14-17

* e-RT3 は，横河電機株式会社の登録商標です。