

操業・設備異常検知モデルPolygon-AIの開発

Unsupervised Anomaly Detection in Mixed Processes Using Clusters

井上 雅貴*
Masataka INOUE

抄 録

操業・設備異常検知技術のひとつとして、日本製鉄(株)が独自に開発した Polygon-AI を紹介する。多品種小ロット大量連続生産を前提とする鉄鋼業においては、異常検知においても多種多様な操業・運転モードへの対応が求められる。Polygon-AI は、データクラスタリング手法のひとつである非負値行列因子分解を応用した技術であり、時系列データに含まれる複数の線形関係性を表現する正常モデルを自動的に抽出し、各々の時点の時系列データの異常度を正常モデルとの距離として計算する。現在、Polygon-AI は発電・エネルギー設備を中心に適用されており、本稿はその理論を解説し、適用事例を紹介する。

Abstract

In this paper, we introduce Polygon-AI as a unique technique for detecting anomalies in operations and equipment of the manufacturing process. In the steel industry, which is based on high-mix, small-lot, mass continuous production, there is a demand for anomaly detection technologies that can deal with a wide variety of operation modes. Polygon-AI applies non-negative matrix factorization, a data clustering method to detect anomalies. It enables us to extract a normal model automatically which describes multiple linear relations between variables in time-series data and quantify the degree of abnormality by gauging the distance between current data and the normal model. Currently, Polygon-AI is mainly applied to power generation and energy facilities. This paper explains the theory of Polygon-AI and introduces its practical applications.

1. 緒 言

鉄鋼業は24時間365日の連続稼働を前提とした素材・プロセス産業である。競争力の維持には、高品質・低コスト・大量生産が不可欠であり、操業・設備の安定化による生産の維持・継続が第一に求められる。特に、製鉄所のインフラ設備である発電・エネルギー設備や、高炉・製鋼等の上工程プロセスにおいては、その要求はより厳しいものとなる。操業・設備が長時間停止する異常やトラブルがひとたび発生すれば、製鉄所全体の生産機会逸失に繋がるため、異常発生を早期に検知し、その原因を取り除くことが重要となる。このような背景から鉄鋼業においては操業・設備異常検知のニーズは高く、過去から現代にいたるまで様々な取り組みが行われてきた。

異常検知で最もよく利用される方法は、監視対象となる操業・設備の時系列データに警報値を設定して、達した場合に警報を発報するというものである。この方法は、操業・

設備を熟知した運転・整備者が異常に対応する適正な警報値を設定できる場合は有効である。ただし、プロセス産業では監視対象の種類と数が膨大、かつ、対象毎の警報値設定が必要であることから、その管理には多大な労力が必要となる。経験豊かなベテランであれば警報値に達する前の異常の兆候を捉える場合もあるが、人間が異常兆候を網羅的かつ継続的に監視し続けることは難しい。

一方、異常発生メカニズムが分かっている場合、統計・物理モデルに基づいた異常検知を行うことが可能になる。しかし、異常発生メカニズムを特定できるケースに限られること、設備・プロセスが大規模、複雑な場合は演繹的なモデル構築が難しくなることから、その利用は限定的となる。

このような背景から近年、異常検知モデルの構築に機械学習を適用することが一般的になってきている。機械学習は、モデル構築のために異常発生メカニズムを予め特定する必要がなく、代わりに過去に観測した時系列データ

* 設備・保全技術センター システム制御技術部 システム制御技術室 制御開発課 主幹 千葉県富津市新富 20-1 〒293-8511

を入力として要求する。一般的には、異常検知に用いる機械学習のアルゴリズムは教師なし学習（データの特徴を自動抽出する学習）であり、正常な状態の操業・運転の時系列データ（正常データ）を入力する。操業・設備の異常データを大量に集めることが難しいこと、また、異常を判定するよりも“正常ではないこと”を判定するほうが合理的であることが、その理由である²⁾。

しかし、機械学習を多種多様な操業・運転モードを含むデータへ単純適用しても信頼性の高いモデルを得られない場合がある。こうした問題の解決手段のひとつに、各々のモードに対応する機械学習モデルを構築しておき、モードに応じてモデルを切り替える方法がある。しかし、モデル構築には人間が試行錯誤的にデータを適当な規模の集合に仕分ける必要があり、多大な労力を要する³⁾。

一方、信頼性の高いモデルを得ることを目的に高度な機械学習、AIを適用すれば、ブラックボックスのモデルを得ることができる。しかし、異常検知は得られた結果を解釈、説明可能であることが要求されることが多いため、モデルは極力単純であることが望ましい。

以上の異常検知技術の課題、ニーズを鑑みて、データクラスタリングを応用した異常検知技術である Polygon-AI を独自に開発した。ここで、データクラスタリングとは多数のデータに対して似たデータ同士を部分集合（クラスタ）に仕分ける手法である。プロセスから得られる時系列データの変数間には、線形関係性が存在することが経験的に知られている^{4,5)}。Polygon-AI は、時系列データに含まれる複数の線形関係性を表現する正常モデルを自動的に抽出し、各々の時点の時系列データと正常モデルの距離を異常度として計算する、日本製鉄独自の異常検知技術である。次章より Polygon-AI の理論と適用事例を説明する。

2. 操業・設備異常検知モデル Polygon-AI

まず、Polygon-AI の基盤となる、データクラスタリング手法のひとつである非負値行列因子分解（NMF：Non-negative Matrix Factorization）について述べる。つぎに、過去に観測した複数の変数からなる時系列データを行列として扱い、NMF を適用することで行列に含まれる共通的な特徴因子（基底行列）が抽出されることを説明する。

Polygon-AI では、抽出された基底行列に係数行列を乗算することで、各々の時点の時系列データを近似する処理を行う。基底行列と係数行列の積が表現する空間は、過去に観測した時系列データから推定される、各々の時点におけるもっともらしい時系列データであり、実際の時系列データとの距離を異常度として計算することができる。

2.1 非負値行列因子分解

非負値行列因子分解（以下、NMF）は、負の値が含まれていない行列の掛け算形式で、元の行列を分解する手法で

ある。NMF はデータクラスタリング手法のひとつであり、負の値が含まれないという条件を課すことで元の行列が持つ特徴因子（基底行列）を抽出し、特徴因子の足し算として表現するという性質を持つ。

$$Y \sim \Phi \cdot X \quad (1)$$

ここで、 Y : 元の行列、 Φ : 係数行列、 X : 基底行列である。全て非負の実数行列である。NMF は行列を係数行列と基底行列の積へと分解するが、得られる係数行列の要素が数学的にスパース（疎）、すなわち要素の殆どが 0 になるという性質を持つ。

一般に NMF の解は、一意に定まらないことが知られている。NMF は以下に示す最適化問題として定義される。

$$\begin{aligned} Y &\sim \Phi \cdot X \\ \text{minimize } &\|Y - \Phi X\|_F \\ \text{subject to} & \end{aligned} \quad (2)$$

$$Y \in R^{T \times M}, \Phi \in R^{T \times N}, X \in R^{N \times M}$$

ここで、 $\|\cdot\|_F$ はフロベニウスノルム（行列の各成分の二乗和の平方根）を表す。また、 Y, Φ, X は非負の実数行列であり、 Y は T 行 M 列、 Φ は T 行 N 列、 X は N 行 M 列のサイズを持つ。式 (2) の最適化問題の解法は、Lee らによって効率的な更新アルゴリズム⁶⁾が提案されている。以下に具体的な手続きを示す。

1. Φ, X の初期値としてランダムな非負値の値を与える。
2. 固定した Φ のもとで最小化問題を解いて X を更新。
3. 固定した X のもとで最小化問題を解いて Φ を更新。
4. 2.～3. の反復計算を繰り返す。

上記の NMF の最適化問題は、初期値により解 X が変化するため、局所解になる。そのため、一般には様々な初期値で計算を行い、複数の解から大域解に近い解を選択するというアプローチが採用されることになる⁷⁾。

2.2 Polygon-AI

Polygon-AI は一般的な機械学習と同様に、異常検知用の正常モデルを学習するアルゴリズムと、学習したモデルを実際の時系列データへ適用するアルゴリズムで構成される。

2.2.1 学習アルゴリズム

本項では、学習アルゴリズムを説明する。Polygon-AI では過去に観測した時系列データを行列として扱い NMF を適用する。ただし、NMF は行列に非負条件が課されることから、様々な値を取るプロセスデータ時系列に対してはそのまま適用できない。そこで、時系列データに対して各変数の測定レンジで割り戻して、0～1 に規格化する前処理を行う。

改めて式 (2) を考察する。 Y : 過去に観測した時系列データ、 Φ : 係数行列、 X : 基底行列、 T は時系列データのサンプル数、 M は変数（項目）の数である。Polygon-AI では、 Y

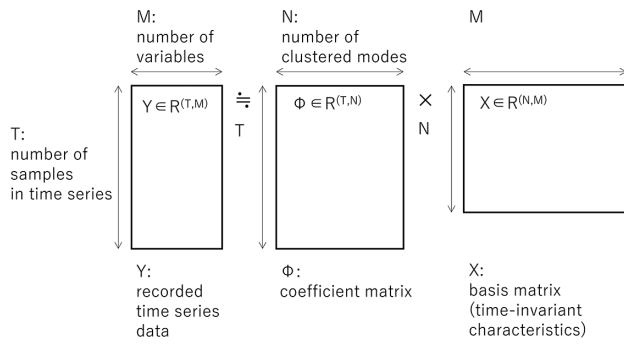


図1 Polygon-AIにおける非負値行列因子分解
Formulation of non-negative matrix factorization in Polygon-AI

にNMFを施して類似のモードを持つクラスタへと仕分けする。このとき、計算される X :基底行列は“操業・運転モードの全サンプルに共通的な特徴に対応する行列”であり、操業状態と呼称することにする。 X の行サイズ: N はクラスタ数である。図1にPolygon-AIにおける非負値行列因子分解のイメージを図示する。

ただし、時系列データにNMFをそのまま適用することは難しい。これは、フロベニウスノルムは行列全体の誤差を最小化するが、各行のデータの復元は保証されないことに起因する。これは、各時点のサンプルにおいて、変数間に不変的に存在する線形関係性が保持されないことを意味する。そこで、Polygon-AIはNMFにおける最適化問題の評価関数を工夫することで、過去に観測した時系列データのサンプルを可能な限り多く復元することを試みる。まず、近似誤差: e を各行のユークリッドノルム(ベクトルの各成分の平方和の平方根)で定義する。

$$\begin{aligned} D &= Y - \Phi \cdot X \\ D &= (d_1 \ d_2 \ \dots \ d_T)^T \\ D &\in R^{T \times M}, d_i \in R^{1 \times M} \\ e &= (|d_1|, |d_2|, \dots, |d_T|)^T \end{aligned} \quad (3)$$

ここで、 e の単純なユークリッドノルムを評価関数とすると、過去に観測されたデータのある時点における局所的な誤差(例えば、 $|d_i|$ の最悪値)により過大評価される場合がある。こうした局所的な誤差を抑制するには、クラスタ数: N を増やすという戦略が有効である。しかし、 N を大きくしすぎればクラスタ毎のデータの量が不足し、統計的な信頼性が損なわれることになる。

一般に、NMFにおいてはクラスタ数: N を既知として計算を行うことになる⁹⁾。しかし、既知の N として実際の操業・運転モードの数を適用すればクラスタ数としては大きすぎる。一方、人間が試行錯誤的に N を決定することは簡単ではない。そこでPolygon-AIでは最適化問題を解くための繰り返し計算の中に、 N を組み込むことで最も精度良く Y を近似する X を最小の N で求めることを試みる。

具体的には、近似誤差: e の各行のユークリッドノルム $|d_i|$ が閾値:thresholdを超えた回数(行の数): β を評価関数

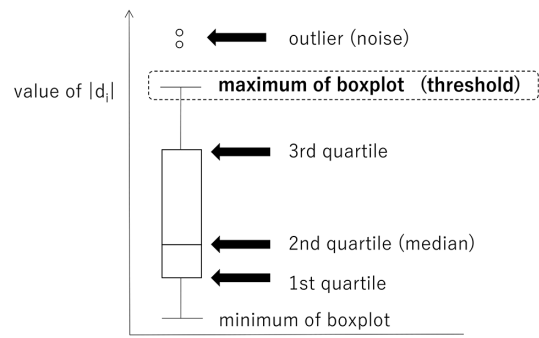


図2 Polygon-AIにおける近似誤差の閾値
Threshold for approximation error in Polygon-AI

として定義する。そして、 $|d_i|$ の閾値:thresholdを箱ひげ図の最大値(図2)として、式(4)により定義する。

$$\text{threshold} = \frac{\text{第3四分位数} + \text{第3四分位数} - \text{第1四分位数}}{2} \quad (4)$$

ここで $|d_i|$ を小さい順に並べて下から1/4に位置するデータを第1四分位数、3/4に位置するデータを第3四分位数と定義する。一般に、異常検知は Y が正常データであることを仮定するが、実際のプロセスデータは外れ値(ノイズ)の混入が避けられない。そこで、近似誤差の外れ値を除外することで、プロセスデータの外れ値に対する X の感度を下げる。

このように、Polygon-AIは過去に観測した時系列データのサンプルから外れ値を除外して可能な限り復元し、かつ、過不足のないクラスタ数を自動的に導出するように定式化されている点に特徴がある。これは多種多様の操業・運転モードを含む時系列データに対応する、シンプルかつ信頼性の高い異常検知モデルを構築したい、というエンジニアの視点に立脚する。

NMFは前述の通り、 Φ :係数行列、 X :基底行列の初期値により解: Φ 、 X が変化する。そのため、Polygon-AIの学習アルゴリズムにおいては、 Φ 、 X に適切な初期値を設定して、繰り返しNMFを実行する。そして、 N を変化させながらNMFの実行を繰り返すことで β を最小化する最小の N 、 X 、thresholdを求める。

2.2.2 適用アルゴリズム

本項は、Polygon-AIの適用アルゴリズム、すなわち実際の時系列データに適用して、“正常ではないこと”を判定する手続きを説明する。先述した学習アルゴリズムから得た操業状態: X は、過去に観測した時系列データ: Y から推定しうる全ての時系列データの集合を表現する。このことは、Polygon-AIの正常モデルが操業状態: X を構成する基底ベクトル: x_j が張る空間であることに対応する。

$$X = \begin{pmatrix} x_1 \\ x_2 \\ \vdots \\ x_N \end{pmatrix} \quad (5)$$

$X \in R^{N \times M}, x_i \in R^{1 \times M}$

オンライン観測される、ある時点での時系列データ: y を対象に、Polygon-AI の正常モデルに対する異常度と乖離度を以下の手続きで計算する。

$$\begin{aligned} &y \sim \phi X \\ &\text{minimize } |y - \phi X| \\ &\text{subject to} \\ &y \in R^{1 \times M}, \phi \in R^{1 \times N}, X \in R^{N \times M} \end{aligned} \quad (6)$$

ここで ϕ : 係数ベクトルであり、非負の制約のもとで NMF を用いて計算する。式 (6) で得られた ϕ に対して、推定誤差のユークリッドノルムを異常度: anomaly score と定義する。また、推定誤差は乖離度: deviation score と定義する。

$$\begin{aligned} \text{anomaly score} &= |y - \phi X| \quad (7) \\ \text{deviation score} &= y - \phi X \quad (8) \end{aligned}$$

乖離度の各要素は、ある時点での時系列データ: y が “正常ではない” 要因となる変数の寄与度を表している。また、 ϕ の配列で一番大きい要素のインデックスがモードに対応する。

$$\text{mode} = \arg \max (\phi) \quad (9)$$

以上が Polygon-AI の理論となる。図 3 に Polygon-AI による異常検知の概念図を示す。操業状態を表す基底ベクトル: x_i が張る空間から推定されるもっともらしいデータと現在のデータとの距離が異常度として与えられる。このように多次元の時系列データに含まれる複数の線形関係性を、過不足なく説明可能な多面体 (Polygon) を自動導出 (AI) することから本技術を Polygon-AI と命名した。

Polygon-AI による異常検知システムの監視画面例を図 4 に示す。1 段目は異常度のトレンドを示す。異常度が閾値: threshold を超過するとメールによる自動通知が実行される。2 段目は異常度に対する乖離度を示す。各変数の “正常ではない” 要因の寄与度が大きいものから上位 5 つの変数を自動抽出することで操業・設備異常の原因分析を支援できるようにしている。

3. 適用事例

本章では、Polygon-AI の具体的な適用事例を紹介する。

3.1 発電・エネルギー設備における異常検知のニーズ

製鉄所における発電・エネルギー設備は、各工場、地域への電力供給を担っており、操業・設備トラブルは生産、地域住民の生活に対して多大なる影響を与えることになる。操業・設備の異常兆候を検知できれば、発電量不足による電力会社へのペナルティ回避、二次被害の拡大防止、停止期間の短縮化などが可能となる。また、オペレータに

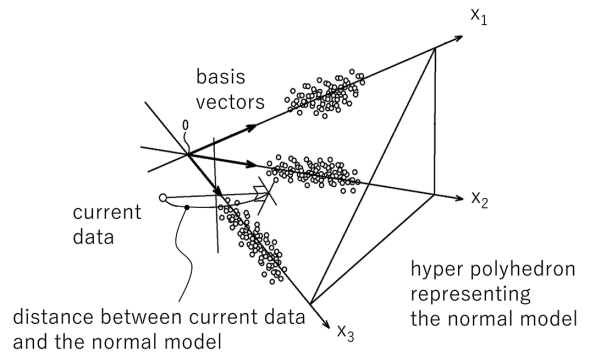


図 3 Polygon-AI による異常検知の概念図
Schematic diagram of anomaly detection by Polygon-AI

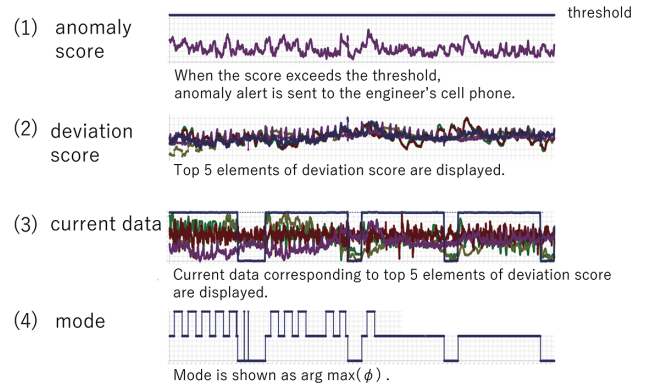


図 4 Polygon-AI による異常検知システムの監視画面例
Example of monitoring screen of Polygon-AI system

よる監視作業のみならず、整備・保全者の異常個所の特定制業を軽減することが期待される。

3.2 ボイラーチューブブリーク

ボイラーチューブブリークとは、配管が経年劣化や熱疲労により破損する現象であり、ひとたび発生してしまうと、破孔箇所から吹き出る蒸気のエロージョンにより二次被害が発生する可能性がある (図 5)。また、トラブルにより発電量不足となり電力会社へのペナルティが発生することに加えて、発生個所を特定するための調査に多大な労力が必要となることから、異常兆候検知・異常個所特定ニーズは大きい。

3.3 Polygon-AI 適用検証

日本製鉄の発電・エネルギー設備で実際に発生したボイラーチューブブリークの過去トラブルの時系列データに対して、Polygon-AI を適用した解析結果を示す (図 6)。

Polygon-AI は、オペレータがチューブブリーク異常を察知するよりも早いタイミングでの異常兆候を検知できている。また、乖離度上昇に対応する変数は、設備・プロセス知見と矛盾しないことも確認できている。このことは、Polygon-AI が有用であることを示す。




図5 ボイラーチューブ破孔の様子
Appearance of boiler tube rupture

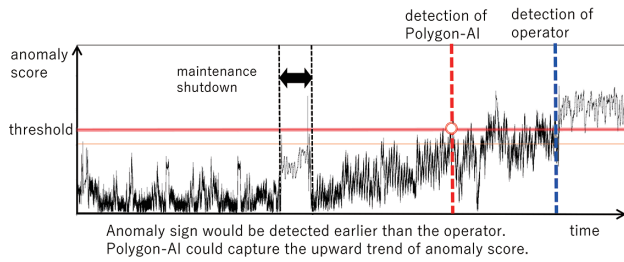


図6 ボイラーチューブリークへの Polygon-AI 適用結果
Polygon-AI validation result for the boiler tube leak incident

4. 結 言

データを活用した操業・設備の異常検知技術である Polygon-AI を紹介した。異常検知技術を活用することで、オペレータの操業・設備の監視負荷を軽減し、トラブル発生を未然に回避できる可能性がある。そこで、操業・保全の業務革新を目指して、結果の説明・解釈が容易、かつ複数の操業・運転モードに対応可能な異常検知技術を開発・

実用化した。

Polygon-AI は現在、発電・エネルギー設備を中心に適用を進めている。今後は、設備安定化統合プラットフォームへの統合、製鉄プロセスへの適用拡大を進めることにより、更なる社業の革新に貢献していく所存である。

参考文献

- 1) 矢入健久：テレメトリマイニング：宇宙システム異常検知・故障診断問題への機械学習的アプローチ. 人工知能. 21 (1), 33-38 (2006)
- 2) 村川正宏：人工知能技術による異常検知システムとその産業応用. 日本原子力学会誌 ATOMOS. 59 (6), 335-339 (2017)
- 3) 茂森弘靖：鉄鋼製品の品質管理へのデータサイエンス適用とデータサイエンティスト育成. システム／制御／情報. 62 (8), 311-316 (2018)
- 4) 藁田昌尚, 落合勝博, 朝倉敬喜, 林司：インバリエント分析技術の大規模物理システムへの適用—原子力発電所の監視への適用を例に—. 情報処理学会デジタルプラクティス. 6 (3), 207-214 (2015)
- 5) 高濱正幸, 三上尚高：ガスタービンプラントの異常予兆検知. 品質工学. 20 (4), 45-51 (2012)
- 6) Lee, D.D., Seung, H.S.: Learning the parts of objects with non-negative matrix factorization. Nature. (401), 788-791 (1999)
- 7) 澤田宏：非負値行列因子分解 NMF の基礎とデータ／信号解析への応用. 電子情報通信学会誌. 95 (9), 829-833 (2012)
- 8) 中尾浩二, 林孝則：Non-negative Matrix Factorization を用いたスペクトログラム特徴抽出と異常検知. 平成 31 年電気学会全国大会講演論文集. 2 (2019)



井上雅貴 Masataka INOUE
設備・保全技術センター
システム制御技術部 システム制御技術室
制御開発課 主幹
千葉県富津市新富20-1 〒293-8511