

データサイエンス活用の異常予兆監視技術

Anomaly-Signs Detection Techniques of Steel Making Facilities Utilizing Data Science

平田 丈英 HIRATA Takehide JFE スチール スチール研究所 サイバーフィジカルシステム研究開発部 主任研究員 (副部長)
蜂谷 由佳子 HACHIYA Yukako JFE スチール 東日本製鉄所 (京浜地区) 制御部 制御技術室 主任部員 (副課長)
鈴木 宣嗣 SUZUKI Noritsugu JFE スチール 設備技術部 主任部員 (副部長)

要旨

鉄鋼プロセスでは、設備などのトラブルが発生すると操業への影響が甚大であるため、設備異常を早期に発見し未然にトラブルを防止することが強く求められている。そこで、これらの問題を解決するために、熱間圧延を対象とする、データサイエンス技術を適用した狙いの異なる 2 つの異常予兆監視システムを開発した。1 つめは、さまざまな操業データからプロセス全体を俯瞰的に監視可能な、かつ汎用性を追求した監視システムである。2 つめは、特定設備に特化した監視システムであり、製品搬送設備の数百台からなるモータの監視システムを開発した。

Abstract:

In steel making processes, influence of an equipment fault on production operation is significant. It is strongly required to detect an equipment fault at an early stage and to prevent the damage. Therefore, techniques to detect fault signs utilizing data science are developed in a hot rolling process. In this paper, two techniques, the one possible to monitor an entire process and the other specified to monitoring hundreds of run-out table motors, are mentioned.

1. はじめに

鉄鋼プロセスでは、設備などのトラブルが発生すると操業への影響が甚大であるため、設備異常を早期に発見しトラブルを未然に防止することが強く求められている。しかし、監視すべき設備数が非常に多く種類も多岐に渡るため、個々に監視ロジックを構築する従来の方法では限界がある。さらに、最近では、導入から数十年経過する設備の割合が増加したこともあり、想定外のトラブルも増加傾向にある。そこで、これらの問題を解決するために、熱間圧延を対象とする、データサイエンス技術を適用した狙いの異なる 2 つの異常予兆監視システムを開発した。1 つめは、さまざまな操業データからプロセス全体を俯瞰的に監視可能な、かつ汎用性を追求した監視システムである。本システムでは、全体、機器、計器のレベル別の監視が可能であり、レベルに応じてビッグデータ解析技術や統計手法など適用手法を変えている。さらに、全体レベルの監視では AI 技術によりトラブル発生源の絞込みも可能とした。これらの技術は、熱間圧延以外のプロセスにも展開可能な汎用性の高い技術である。2 つめは、特定設備に特化した監視システムである。本論文では、仕上圧延機から巻取り機の間にあるランナウトテーブルと呼ばれる製品搬送設備の数百台からなるモータに特化した監視システムの開発事例を報告する。本システムは、

数百台のモータ間に生じる機差を統計手法により除去することにより、モータ 1 台ごとの個別の監視ロジックを構築し、メンテナンスを不要にしたという実績がある。本論文では、これら狙いの異なる 2 つのシステムについて、実例を交えて紹介する。

2. プロセス全体監視技術

2.1 概要

熱延プロセスの特徴は、多種多様な機器や設備から構成され、さらに階層的な構造を示す点にある。そこで、**図 1** に示すように、計器レベル、機器レベル、全体レベルのレベル別監視を構成し、各レベルに適切な手法を適用した。

下位の計器レベルは、従来の上下限チェックで対応できる監視である。中位の機器レベルは、主成分分析 (Principal Component Analysis, 以下 PCA) を用いた波形監視と、データ駆動型モデルを用いた変数間相関監視を主要な監視手法として導入した^{1,2)}。上位の全体レベルは、扱う変数項目が数百以上と膨大になるため、ビッグデータ解析に有利なスパースモデリングの一種である Lasso 回帰³⁾ に基づく手法を導入した。いずれの場合も正常時の基準に対するはずれ度合いを異常度として指標化した。

監視対象が膨大な量となることから、効率的に監視するために、監視対象別の異常度の経時変化を、その大きさに応じてヒートマップ表示した。表示例を**図 2**に示す。縦軸

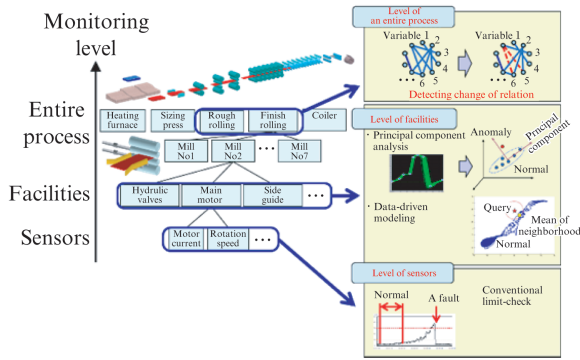


図1 レベル別異常予兆監視

Fig. 1 Concept of anomaly signs detection by hierarchy level of a manufacturing process

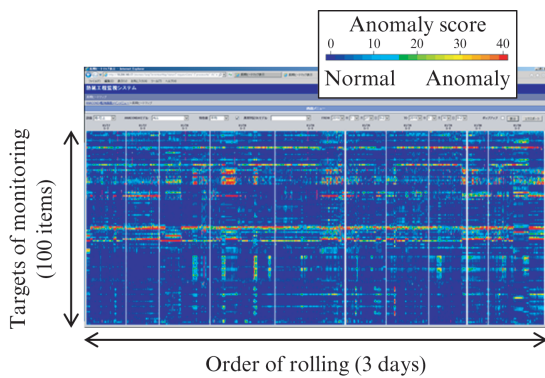


図2 ヒートマップ表示

Fig. 2 Example of heatmapping display

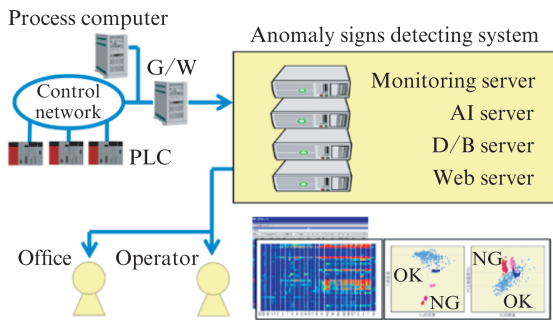


図3 システム構成

Fig. 3 System configuration of anomaly signs detection


は監視対象、横軸は圧延順であり、1つのセルは圧延材ごとに演算した異常度のスコア（平均値などの統計量）を示す。

本システムの概要を図3に示す。ヒートマップは操作室、事務所等でWeb閲覧可能である。また、着目すべき変数が特定されるので必要に応じて散布図などのグラフの自動作成も可能である。散布図では、正常材とトラブル材の比較を容易に行える。

2.2 全体レベルの監視


熱延プロセスの全体レベルの監視に適用した Lasso 回帰

Learning To construct models of relationship among variables under normal operation



$$\begin{aligned} X1 &= a12 \cdot X2 + a14 \cdot X4 \\ X2 &= a21 \cdot X1 + a24 \cdot X4 \\ X3 &= a31 \cdot X1 \\ X4 &= a41 \cdot X1 + a42 \cdot X2 \\ X5 &= - \end{aligned}$$

Monitoring To detect breakage of local relationship by estimating prediction error



$$\begin{aligned} X1 &= a12 \cdot X2 + a14 \cdot X4 \\ X2 &= a21 \cdot X1 + 0 \cdot X4 \\ X3 &= a31 \cdot X1 \\ X4 &= a41 \cdot X1 + 0 \cdot X2 \\ X5 &= - \end{aligned}$$

$$\text{Anomaly score} = f(X_i \text{ actual} - X_i \text{ prediction})$$

Prediction error

図4 全体レベルの監視

Fig. 4 Application of Lasso regression method to detecting anomaly signs of the entire process




図5 全体監視の予兆検知例

Fig. 5 Example of detecting anomaly signs by the level of the entire process

によると、微小な影響係数がゼロとなるため不要な説明変数を大幅に削減することが可能となる。概要を図4に示す。あらかじめ準備した正常時のデータに対して変数別の予測モデルを構築し、監視判定時に新たに得られた実績値に対して予測誤差を演算する。判定対象のデータが正常であれば予測誤差は小さく、異常であれば大きくなるため、予測誤差に基づき変数別に異常度を演算できる。

仕上圧延プロセスを対象とした予兆検知例を図5に示す。図に示すのは圧延機の機械精度状態を示す指標に対する異常度のチャートである。上昇傾向にあった異常度が補修後に低下しているのが確認できる。

2.3 機器レベルの監視

機器レベルの監視には、PCAを用いた波形監視と、データ駆動型モデルを用いた変数間相関監視を主要な監視手法として導入した。はじめに、PCAによる波形監視について説明する。一定の繰り返し動作を示す設備は、その設備の状態を示す信号の波形が一定であり、異常時には波形が乱れることが多く、これを予兆ととらえる。そこで、PCAを用いて波形の乱れを検知し異常診断する方法を開発した^{1,2)}。位置決めモータは一定の繰り返し動作を示す典型的な設備である。図6は位置決めモータで駆動される設備の




図6 PCAによる波形監視

Fig. 6 Application of PCA method to detecting anomaly signs in a facility

移動量の波形を示した図である。波形を構成するサンプリング点が k 点あるとすると、1つの波形は k 次元空間上では1点に対応する。隣り合うサンプリング点は相関があるため、正常時の波形は k 次元空間上で互いに相関を有する形で分布する。ここでPCAを適用することで、正常時の波形を主成分として抽出することが可能となる。図6に示すように、ハンティングなどにより波形に乱れが生じるときは主成分から外れるので、主成分に垂直な成分から定義される逸脱度を算出し、監視することで異常予兆を検知できる。計算式を以下に示す^{4,5)}。 T^2 統計量は主成分方向の指標、 Q 統計量は主成分に垂直な方向の指標である。

$$T^2 = \sum_{r=1}^R \frac{t_r^2}{\sigma_{tr}^2} \quad Q = \sum_{p=1}^P (x_p - \hat{x}_p)^2 \dots\dots\dots (1)$$

σ_{tr} : 第 r 主成分得点 t_r の標準偏差
 R : 主成分数
 P : データ項目数

次に、データ駆動型モデルを用いた変数間相関監視について説明する。図7で示すように、正常時の設備状態を示す変数間に一定の相関がある場合に、過去の正常実績をデータベースに事前登録し、判定対象の計測値を取得したときに、判定対象とデータベースに事前登録したデータ間との距離を求め、距離を逸脱度として定義し監視する方法である。変数間に一定の関係がある設備であれば種類を問わず監視対象となる。距離 d の計算式を以下に示す。

$$d = \sqrt{\sum_{p=1}^P (x_p - q_p)^2} \dots\dots\dots (2)$$

P : データ項目数

仕上巻取機における予兆検知例として、巻取開始直後の設備動作波形をPCA手法により監視した結果を図8に示す。ここで、上昇傾向にあった異常度が補修後に低下している

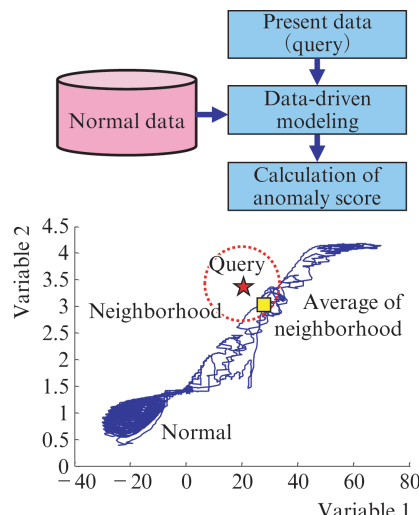


図7 データ駆動型モデルによる相関監視

Fig. 7 Application of data-driven modeling method to detecting anomaly signs in a facility




図8 機器単体の予兆検知例

Fig. 8 Example of detecting anomaly signs by the level of facilities

のが確認できる。

2.4 AI 推定技術

前述の全体レベルの監視では、異常の発生源が回帰モデルを通して他の変数に伝播し結果的に複数の変数で異常が観測されるという問題がある。説明を容易にするために5つの変数を対象とした場合の例を図9に示す。異常の発生源を X_2 と仮定した場合、 X_2 を説明変数に有する X_1, X_4 でも異常度が上昇する。実際には、変数が百以上あり、複数の異なる異常が併発することもあるため、異常の発生源を特定しがたい。そこで、AIを利用して推定する方法を開発した。人工的に微小異常を加えたデータをさまざまに組合せてディープラーニングにより学習を行うことで、異常の発生源を推定する方法である。過去発生した5つのトラブルに対する推定結果を表1に示す。集約率(異常度があらかじめ設定した閾値を超えた項目数に対する発生源として推定した項目数の比率)は7~33%であり、トラブルの分析から判断される検知すべき変数について見逃しはないため、推定




図9 異常の発生源の伝播

Fig. 9 Image of propagation of anomaly source

表1 AI推定結果

Table 1 Result of AI estimation

	Fault A	Fault B	Fault C	Fault D	Fault E
Number of variables whose anomaly score exceeded the threshold	45	15	39	17	10
Number of variables estimated as anomaly sources	3	5	5	3	3
Number of missed variables that must be detected	0	0	0	0	0
Number of variables not valid as anomaly sources	0	3	3	0	1

は妥当と言える。

3. 搬送モータ監視技術

ランナウトテーブルは、仕上圧延機から巻取り機の間であり、鋼板の巻取り前の目標温度に向けて冷却が行われる搬送設備である。テーブルは数百台のロールと、各々に付随する同数のモータで構成されており、カップリング異常やモータへの異常負荷による不回転が生じると、搬送される鋼板に疵が発生するため、長時間のライン停止を引き起こす。図10に、モータへの速度指令に対する負荷電流の挙動を示す。正常搬送時は、モータに対する速度指令に対し負荷電流は加速・減速時にピークが発生し、定速はほぼ一定値をとる。一方、モータに異常が発生すると、正常値の波形から外れる波形が観測される。

モータの異常を事前に検出するため、モータの聴音の実施および電流測定値の閾値超えで異常検出する方法が運用されてきた。前者は、限られた時間内で制御保全スタッフが数百台の聴音を実施する必要があり、また担当者の長年の経験に依る部分も大きいため、異常を見逃す可能性がある。後者は、異常をリアルタイムで知ることが可能であるが、加速、定速、減速時に電流の挙動を把握した上で、各々モータ個々の機器特性を考慮して閾値を決める必要があり、場合によっては異常を誤検出する可能性もある。

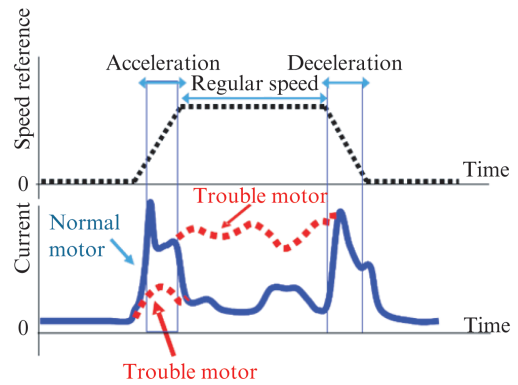


図10 モータの速度指令と電流実績

Fig. 10 Speed reference and current of motor




図11 PCAによるランナウトモータ監視

Fig. 11 Application of PCA method to monitoring run-out motor current

これらの課題を踏まえ、PCAを用いたランナウトモータの監視手法について述べる⁶⁾。基本的に隣りあうモータ間では同様の動作を行うので、モータ電流間では高い相関を示す。これにPCAを適用すると、図11に示すようにモータの機差も含めて正常時の動作を主成分として示すことができる。モータに異常があった場合には、主成分から外れるので主成分に垂直な成分から定義される逸脱度を算出し、監視することで異常予兆を検知できる。従って、1台ごとに閾値を調整するような必要はない。なお、本法はモータ間の相関からの外れを監視するため、「2.3 機器レベルの監視」で述べた波形監視でのPCAの利用方法とは異なる。

次に、監視システムについて述べる。図12にシステム構成を示す。ランナウトモータに設置したホールCTセンサにより電流実績をデータ収集装置に取り込む。ランナウトテーブルのモータは前半から約100台ずつ、電気的に計3つのグループを構成しており、鋼板の通過位置により各グループに与えられる速度指令が異なる。また、モータの電流波形は図10で示したように加速時、定速時、減速時など速度パターンにより異なる。以上により、PCAは速度指令の異なるグループ別、速度パターン別にモデルを構築し、監視することとした。

図13に、329台のうち1台のモータが、ロールとのカップリング破損により不転となるトラブルが発生した場合の、定速時の収集データにおける T^2 統計量、 Q 統計量の推移を




図 12 ランナウトモータ電流監視システム

Fig. 12 Run-out motor current monitoring system

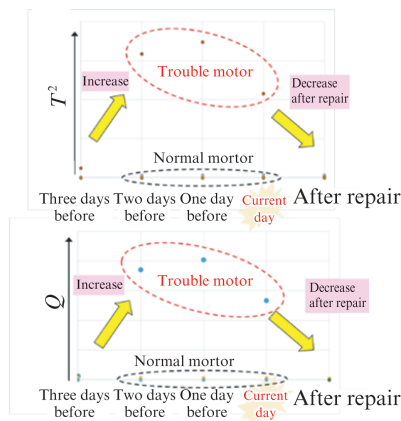


図 13 異常・正常モータの T^2 統計量, Q 統計量

Fig. 13 T^2 and Q statistics of failed motor and others

示す。トラブル発生日の1~2日前より、異常モータの T^2 統計量と Q 統計量が、他の正常モータより大きく変化していることが分かる。このことから、モータの異常性を T^2 統計量と Q 統計量で表す本 PCA 手法が有用であると言える。

4. おわりに

データサイエンス技術を適用した熱間圧延での異常予兆

監視技術に対する新たな取り組みについて紹介した。1つめは汎用性を追求したプロセス全体の監視が可能な異常予兆監視技術であり、階層構造を示す各機器・設備に対するレベル別監視システムを提案し、各レベルに応じて適切な異常度解析手法を適用することにより、網羅的な異常予兆監視ができるシステムを構築した。2つめは製品搬送のモータに特化した監視技術であるが、構成する数百台のモータを監視するロジックを効率よく構築するための、PCAを適用した技術を紹介した。これらの2つのシステムは異なる地区で開発されたものであるが、今後は機能統合して1つのシステムとして構成し、さらなる設備異常の未然防止により生産安定化を推進していく所存である。

参考文献

- 1) Hirata, T. et al. A Fault Detection Technique for the Steel Manufacturing Process Based on a Normal Pattern Library. IFAC-PapersOnLine. Paris, 2015, vol. 48, issue 21, p. 871-876.
- 2) 鳴瀬卓也ほか. 鉄鋼設備のために開発・導入された状態監視技術. トライボロジスト. 2017, vol. 62, no. 11, p. 671-678.
- 3) Tibshirani, R. Regression Shrinkage and Selection via the Lasso. Journal of the Royal Statistical Society, Series B(Methodological). 1996, vol. 58, issue 1, p. 267-288.
- 4) Jackson, J. E.; Mudholkar, G. S. Control procedures for residuals associated with principal component analysis. Technometrics. 1979, vol. 21, p. 341-349.
- 5) Jackson, J. E. Principal components and factor analysis: Part I — principal components. J. of Quality Technology. 1980, vol. 12, p. 201-213.
- 6) 木津健. 多変量統計のプロセス管理による熱間圧延ライン製品搬送モータ異常検知. ものづくり研究会 金属産業応用一般. 2018, MK-18-011.



平田 丈英



蜂谷 由佳子



鈴木 宣嗣