

異常兆候を検知し回避手順を示すプラント運転支援システム

Plant Operation Support System that Detects Abnormality Sign and Provides Guidance on Avoidance

鳴海 克則 NARUMI, Katsunori

鈴木 聡 SUZUKI, Satoshi

館山 淳也 TATEYAMA, Junya

プラント操業では、さまざま場面に依りて適切に操作ができる技術が求められている。また、プラント設備では運転データなど多様なデータが大量に蓄積されている。富士電機は、大量のデータを解析することにより、適切な操作を行うことができるプラント運転支援システムを開発した。多変量解析などによる複数の予測モデルを用いて同時に予測を行い、予測値を総合することで予測精度が向上する。これにより、精度の高い異常兆候を早期に検知できる。また、異常兆候を検知すると回避手順データベースから該当する回避手順を検索し、ユーザーに通知する機能も実装した。

Plant operations require technologies capable of performing appropriate operations in various situations. Plant equipment stores large amounts of various types of data, such as operation data. Fuji Electric has developed a plant operation support system that can perform appropriate operations through the analysis of large amounts of data. The system uses multivariate analysis with multiple prediction models to perform simultaneous prediction and aggregates predicted values to improve predict accuracy. This allows for early detection of abnormality sign with high accuracy. When detecting an abnormality sign, it will search the database for avoidance procedures to inform users of them.

1 まえがき

プラントの安定・安全操業を支えてきた熟練オペレーターが減少し、非常操作や緊急操作の経験が十分に伝承されていない。また、操業手順を完全にマニュアルに落とし込むことは困難であり、自動化ソフトウェアやモデルを構築することもマンパワーやコスト面で現実的ではない。一方、プラント設備の監視制御システムには、過去の運転データ（センサなどから得られる運転データ）やオペレーターの操作および制御動作などのイベントログ、アラームログなど多様なデータが大量に蓄積されている。

富士電機はこれらの課題を解決するため、監視制御システムに蓄積された大量のデータ（ビッグデータ）を解析することにより、異常兆候を早期に検知（異常兆候検知）し、異常を未然に回避する手順（回避手順指示）を示すプラント運転支援システムを開発した。

2 プラント運転支援システムの全体構成

2.1 プラント運転支援システムのニーズ

プラントでは、製造する製品の品質を確保するために、品質に影響を与えるプロセス変数に対して上下限值を設定し、異常の有無を判断することが一般的である。しかし、複数のプロセス変数に相関関係があることから、個々の変数の監視だけでは適切な判断が難しい。また、プロセス変数が大きく変動していても品質が確保できる正常な運転状態もある。このように、上下限值の設定だけでは適切な判断が難しいという問題もある。そのため、複数の変数間の相関を考慮しながら診断する技術が求められている。

プラントの起動・停止や異常発生時などの非常運転時には人手による対応が必要となる。しかし、プラントの異

常を経験する機会が減っていることや熟練オペレーターの減少などによって、対応に時間がかかっている。操業はマニュアルに沿って原則行われているものの、手動操作の場合はオペレーターの経験に沿って操作が異なることもあり、さまざまな場面に依りて最適な操作を行うことができる技術が求められている。

このような課題に対して、プラントにおける計測トレンドデータやアラームデータ、動作ログデータ、手動による操作のログデータを分析してプラントの操業支援に活用することが望まれている。

2.2 プラントにおけるログデータと運転データ

プラントにおいて大別するとログデータと運転データが収集・蓄積される。

ログデータは、監視制御システムが発するアラームのログの他、制御システムの動作ログ、オペレーターによる操作ログなどがある。

運転データには、監視制御システムが計測しているセンサデータ（流量、圧力、温度、水位など）に加えて、制御系の設定値やバルブなど、アクチュエータの指令値と応答（開度や電流値）も含まれる。

2.3 データ解析による運転支援

図1にプラント運転支援システムの模式図を示す。プラント運転支援システムは、蓄積したログデータと運転データを活用して、プラントの運転支援を行う。

まず、データからプラントの挙動を何らかの形式で模擬するモデルを構築する。モデル化の方法には、ログデータの場合はパターン分類、運転データの場合は多変量解析などがある。このようにして構築したモデルに直近のデータを入力する、あるいは比較することにより、現在のプラン

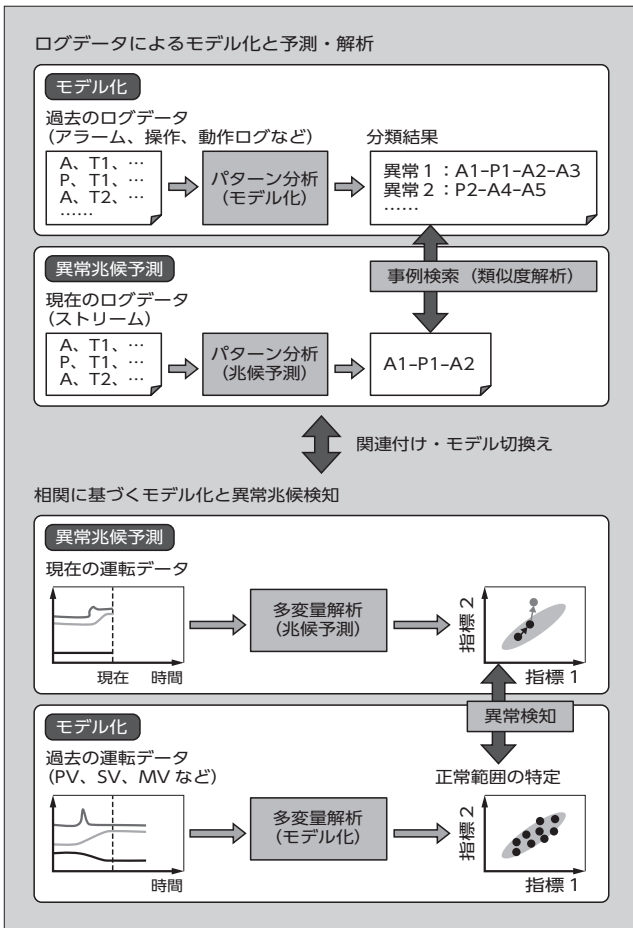


図1 データ解析によるプラント運転支援システム

ト運転状態を推定、あるいは予測して運転支援に利用する。

2.4 システム全体構成

図2にプラント運転支援システムの全体構成を示す。このシステムは監視制御システムと連携して、プラントデータに基づき異常兆候予測を行い、異常に対する回避手順候補をユーザーに通知する。

3 異常兆候検知

3.1 異常兆候検知の必要性

プラントの異常監視においては、監視対象となる連続量を変数（監視変数）として、設定した管理限界（上下限の管理しきい値）を逸脱したときにアラームを発することが一般的である。これに対し、監視変数の未来値を予測し、その予測値が管理限界を逸脱することで異常の予兆検知を行う異常兆候予測では、プラント異常が発生する前にオペレーターが回避操作を行い、事前に異常を回避できるので、より効果的である。

ここでは、監視変数の予測に基づく異常兆候予測の概要と、予測値に対する管理限界の設定の仕方によりユーザーの仕様に合った予測精度を得るための方法について述べる。

3.2 予測器によるアラーム発生予報

予測器とは、ある連続変数の未来値を、現在までに得られている情報から予測するモデルである。予測器には、一般に物理モデルによるものと統計モデルによるものがある。プラント運転支援システムでは、次に示すオンラインとオフラインの枠組みによって、物理モデルと統計モデルの両方に対応できる。

予測器を用いた異常兆候の予測の手順を図3に示す。プロセス予測値が管理しきい値を超えることを“異常兆候”として扱う。プラント運転支援システムは、プロセス計測値の近い将来の予測を行い、予測値が管理の上限しきい値を上回るまたは下限しきい値を下回ると予測されたときに“異常兆候を検知した”と通知する（図4）。

オフラインにおいて、過去の計測データを使う統計モデルや物理現象を数式で表した物理モデルなどを使って、時間 T だけ未来の監視変数の値を予測する予測器を構築する（図5）。次にこの構築した予測器を用いて、オンラインで監視変数の時間 T だけ未来の値を時刻ごと（1分周期ごと）について予測する。こうして得られた予測値が予測値用管理しきい値を逸脱すると、異常兆候検知を発報する（図6）。




図2 プラント運転支援システムの全体構成

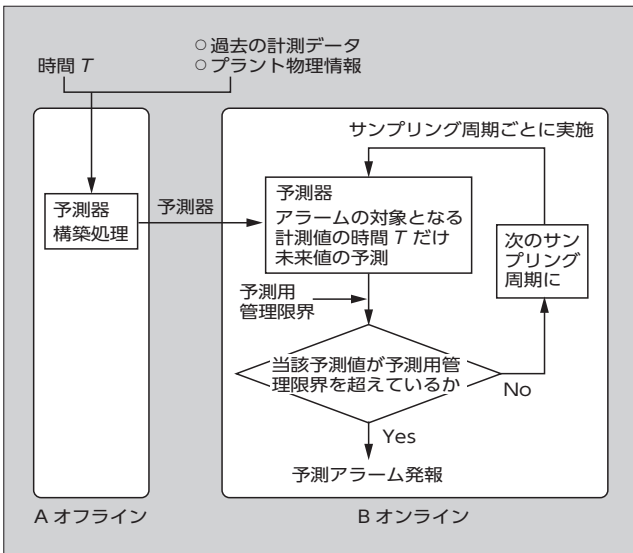


図3 予測器による異常兆候予測の枠組み




図4 予測器による異常兆候予測の概念図




図5 予測器の学習

3.3 異常兆候予測の精度評価と管理限界の設定

3.2節で述べたように管理限界での異常兆候予測による各時刻（1分周期ごと）の異常判定結果は、監視変数予測値の管理限界からの逸脱の有無と、それに対応する実績値の逸脱の有無により、表1のいずれかに分類される。逸脱

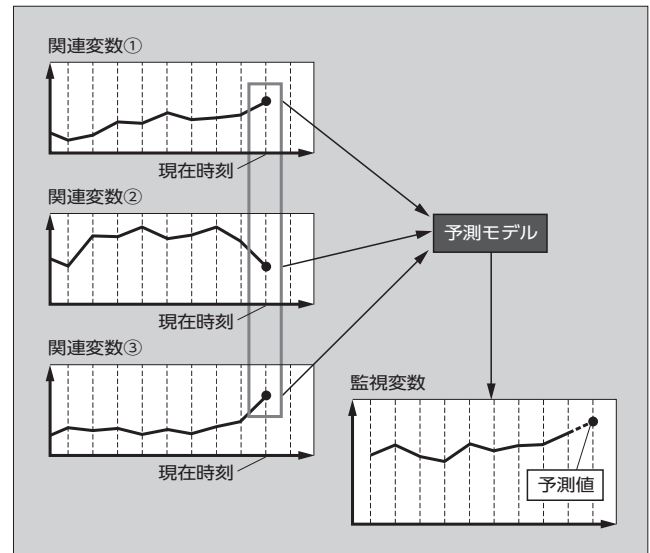


図6 予測器による予測

表1 異常兆候予測の逸脱の有無

項目		実績	
		正常	異常
予測	異常	③誤検知	④正しい予測
	正常	①正しい予測	②検知漏れ

しない場合を正常、逸脱した場合を異常としている。

①と④が正しい予測であり、②は検知漏れ、③は誤検知である。

一般に、次の二つの指標の式(1)と式(2)を使って異常兆候予測の精度を評価する。この二つの指標はトレードオフの関係にあるため、一方を小さくすると他方が大きくなる。例えば、誤検知が増えても検知漏れをなくすなどの安全サイドの判断になるような最適化を図る。

$$\text{検知漏れ率} = \frac{\text{②}}{\text{②} + \text{④}} \dots\dots\dots(1)$$

$$\text{誤検知率} = \frac{\text{③}}{\text{③} + \text{④}} \dots\dots\dots(2)$$

$$\text{予測正解率} = \frac{\text{④}}{\text{②} + \text{④}} \dots\dots\dots(3)$$

実績値と予測値は図7に示すように正の相関がある。す




図7 実績値と予測値の散布図による評価（模式図）

ると、実績値に対する管理限界（実績値用管理限界）は図の縦線、予測値に対する管理限界（予測値用管理限界）は図の横線に対応する。

ここで、予測値用管理限界を変化させると①～④の値が変化し、誤検知率や検知漏れ率も変化する。したがって、過去の監視変数の実績値とそれに対応する予測値があれば、予測値用管理限界を変化させ、これに連動して図7に示すように散布図上で①～④の数値や漏れ検知率、誤検知率を表示することで適切な予測値用管理限界をユーザーが定めることができる。

3.4 予測器の構成

ここで、予測器の構成方法について述べる。プラント運転支援システムでは、予測器として機械学習を使った予測モデルを用いた（表2）。

(1) PLS（部分的最小二乗法）

プラントの監視対象の変数に対して、他の計測変数との関係を、運転データに基づき部分的最小二乗法（PLS：Partial Least Squares）でモデルを作成した。PLSは、入力変数同士に相関がある場合にも、それらを潜在変数と呼ばれる中間変数に集約した上で出力変数を表現する。そのため、多重共線性^(注)がある場合でも、適切なモデルが得られる。

また、PLSでは入力変数が多くても、重回帰分析モデルのように事前分析で入力変数を絞り込む必要がなく、そのまま全変数を用いて簡単にモデルを作ることができる。そのため、モデル作成の手間を非常に軽減できる。このようにPLSは、特に入力変数が多いプロセスや多重共線性を持つプロセスを対象とする場合に非常に有用である。

PLSモデルによる監視対象変数の推定値は、式(4)で得られる。

$$\hat{y} = Q(W^T P)^{-1} W^T x \dots\dots\dots(4)$$

- \hat{y} : 監視対象変数の推定値（スカラー）
- x : モデルへの入力変数ベクトル
- W : 重み行列
- W^T : 行列 W の転置行列
- P, Q : 入力変数と推定値に関する係数行列

表2 予測モデルの方式

方式	特徴
PLS (部分的最小二乗法)	監視変数と監視変数に関連する変数の相関がある対象に向く。 ○ バイアスがある監視変数の場合は差分予測を使用する。 ○ 監視変数に関連する変数の過去値との相関がある場合はダイナミック化を使用する。
LW-PLS (局所部分的最小二乗法)	非線形要素、特性変動に対応が可能である。
ARMA (自己回帰移動平均法)	監視変数の変化傾向を捉えることに向く。

なお、通常の PLS モデルでは、入力変数の現在値に対する出力変数の現在値を推定する。これに対して、今回のモデルは予測器として使用するの、入力変数の現在値に対する出力変数の将来の値を推定する。さらに、将来の値を推定するときに、現在値だけでなく過去値の影響も考慮したい。そこで、プラント運転支援システムでは、入力変数の過去値と出力変数の現在値から推定を行うモデルを構築している。さらに、PLS モデルの入力変数を多重化して、入力変数の過去値（5 分前、10 分前、15 分前、…）と出力変数の現在値との関係をモデル化している（図8）。

(2) LW-PLS（局所部分的最小二乗法）

局所部分的最小二乗法（LW-PLS⁽⁴⁾：Locally-Weighted Partial Least Squares）は、事前に予測モデルを構築するのではなく、プラントの特性変動に追従し、現在値と類似の過去データから予測モデルの再構築を繰り返すことのできる非線形 PLS の一つである。

(3) ARMA（自己回帰移動平均法）

自己回帰移動平均法（ARMA：Autoregressive Moving Average）は、予測対象の複数の過去値から予測値を求める方法なので、予測値の変化傾向を捉える場合に向いている。

3.5 アンサンブル機能

一つの予測モデルを使用し続けると、プラントの経年変化などにより、予測精度が下がる。また、プラントに特性変動がある場合は、一つの予測モデルだけでカバーすることは難しくなる。

これらの課題に対応するために、プラント運転支援システムでは複数の予測モデルを用いて同時に予測を行い、それらの予測値を総合することによって予測精度を向上させる仕組みを備えている。この仕組みをアンサンブルと呼んでいる。アンサンブルは、複数の予測モデルの予測値の重み付き平均を求めることにより、最終的な予測値を得る。

重みは、各予測モデルの予測誤差の成績に応じて自動調




図8 多重化および過去値を用いた予測モデル

〈注〉多重共線性：入力変数の間に強い相関関係があると、一般的な重回帰分析では適切なモデルが構築できないことをいう。




図9 アンサンブル機能

整され、予測精度の高い予測モデルが優先されるようになる(図9)。

また、プラント運転支援システムでは、PLSモデルを一定期間ごとに自動生成してアンサンブルに加える仕組みもあり、これにより、経年変化に応じてモデルを再構築し、精度の維持を図っている。

3.6 評価実験結果

あるプラントデータで一定の期間を学習期間として、その間のデータを使って予測器(PLSモデル)を作成した。学習期間とは別の期間を評価期間として、設定した管理限界に基づいて異常兆候検知の精度を評価した。

その結果、予測正解率(式(3))は83%と検知漏れ率(式(1))は17%であった。

4 回避手順指示システム

4.1 回避手順指示システムによる運転支援

多くのプラント運転の現場では、異常を検知したらオペレーターは経験に基づき異常を回避する操作をしている。一方で、プラントの信頼性の向上と自動化が進み、異常を経験する機会が減っていることや経験豊富なオペレーターが減少しているという課題がある。

この課題を解決するため、プラント運転支援システムでは回避操作の手順(回避手順)を自動的に表示する機能も実装している。

4.2 回避手順指示システムの機能構成

プラント運転支援システムは、オフライン(エンジニアリング)機能とオンライン(運転支援)機能とで構成している(図10)。

(1) オフライン(エンジニアリング)機能

オフライン機能は、過去の操業データから対象とする異常の発生と関連の強い操作データを抽出し、回避手順をデータベースとして蓄積するエンジニアリング機能である。

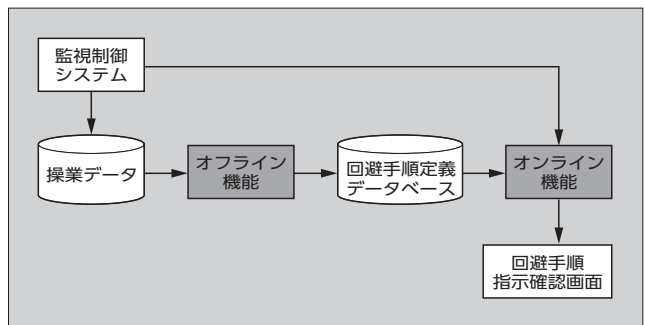


図10 回避手順指示システムの機能構成

オフライン機能の概略フローを図11に示す。

- (a) 過去の操業データから異常発生時点のデータを切り出す。
- (b) 操作ログを検索して異常を回避し、復旧するために操作した履歴を抽出する。
- (c) ユーザーに提示し、確認後、当該の操作ログを回避手順情報として登録する。

オフライン機能においてユーザーに提示する画面のイ

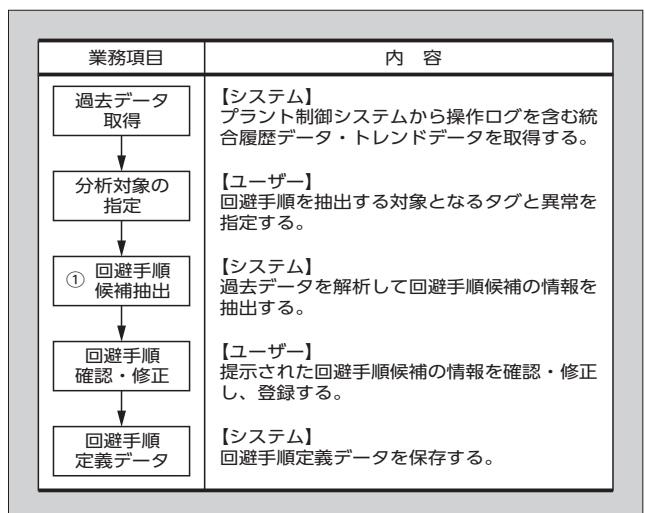


図11 オフライン機能フロー

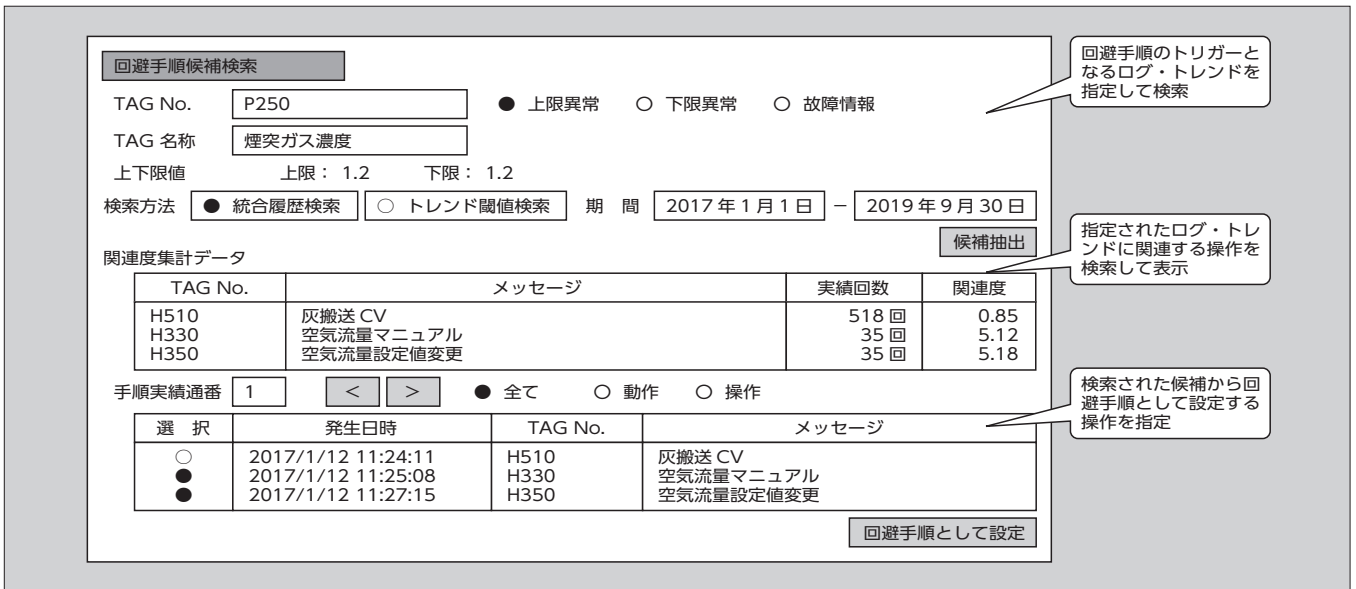


図 12 オフライン機能画面




図 13 オンライン機能フロー

メッセージを図 12 に示す。

(2) オンライン（運転支援）機能

オンライン機能は、プラント運転中の異常の兆候を監視し、異常の兆候を検知すると回避手順データベースを参照して該当する回避手順を検索し、ユーザーに通知する運転支援機能である。オンライン機能の概略フローを図 13 に示す。

- (a) 異常発生を検知する。
- (b) 回避手順定義データベースを検索して、定義されている回避手順を提示する。

オンライン機能においてユーザーに提示する画面を図 14 に示す。

4.3 エンジニアリング精度向上の技術

ここでは、回避手順候補抽出機能（図 11 ①）を実現する上で課題となった事項と、その対策を示す。

(1) 課 題

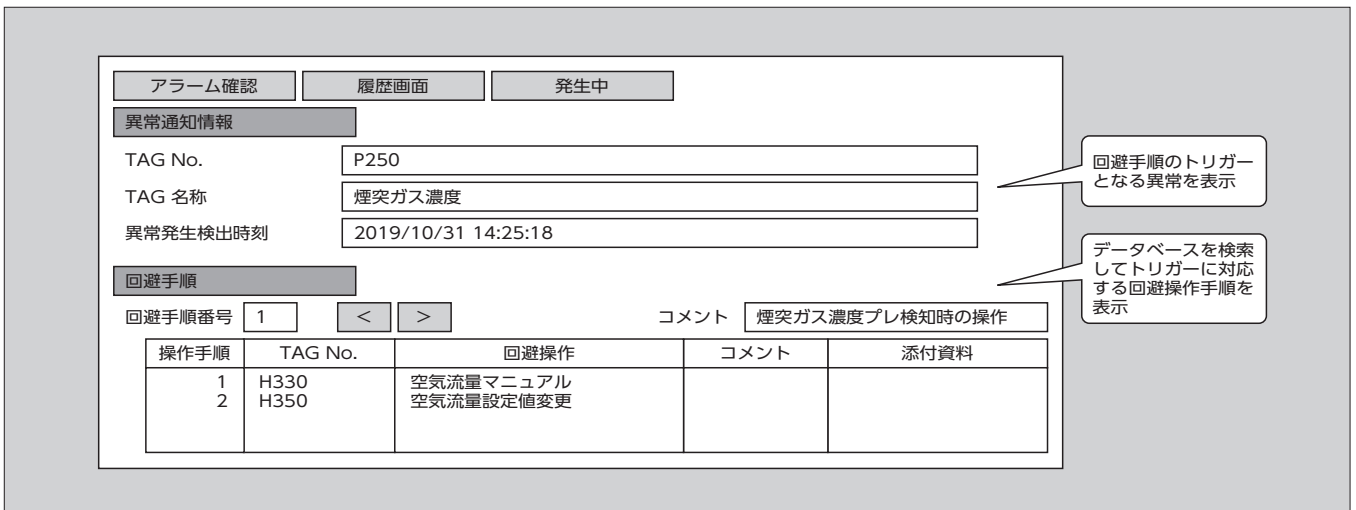


図 14 オンライン機能画面

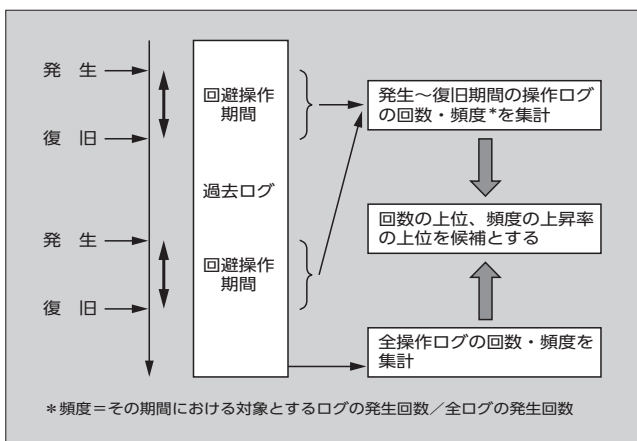


図 15 エンジニアリング精度向上の技術

一般にプラントの監視制御システムにおいては、多種多様なログが同時に発生する。オフライン機能（エンジニアリング）において過去の運転データを解析する際に、対象とする異常に関連する操作だけを抽出できるようにすることが必要であった。

(2) 対策

異常発生時には、平常時に比べて特定の運転ログが高頻度で出現することに着目した。この傾向を利用して、図 15 に示すように対象とする異常と各運転ログの関連度を算出し、関連度で運転ログをフィルタリングして回避手順の候補を抽出する技術を開発した。

⑤ あとがき

異常兆候を検知し回避手順を示すプラント運転支援システムについて述べた。

異常を事前に検知し、その回避手順まで指示することで非熟練オペレーターによる安定・安全操業、およびオペレーターの負荷低減に貢献できると考えている。

近年、特に高まっているプラント設備の安全かつ効率的な運転に対する操業支援ニーズに対して、プラント運転支援システムを監視制御システムと連携することにより、プ

ラント設備の安全性の向上と高効率化への貢献を図っていく所存である。

参考文献

- (1) 松井哲郎ほか. プラント制御におけるデータ分析技術. 富士電機技報. 2014, vol.87, no.1, p.33-37.
- (2) 村上賢哉ほか. アラーム予測モデルの精度評価方式の開発. 2014, 電気学会全国大会.
- (3) V. Venkatasubramanian. et al. “A review of process fault detection and diagnosis Part I : Quantitative model-based methods, Part II : Qualitative models and search strategies, Part III : Process history based methods.”. Computers and Chemical Engineering, 2003, vol.27, p.293-346.
- (4) 加納学ほか. プロセスケモメトリクスによる統計的プロセス管理. システム/制御/情報, 2004, vol.48, no.5, p.165-170.



鳴海 克則

鉄鋼分野の計測制御システムのエンジニアリング業務に従事。現在、富士電機株式会社パワエレシステム インダストリー事業本部オートメーション事業部技術第一部担当課長。



鈴木 聡

情報・制御システムの研究開発に従事。現在、富士電機株式会社技術開発本部デジタルイノベーション研究所 AI ソリューションセンター AI 研究部主任。計測自動制御学会会員、人工知能学会会員。



館山 淳也

情報・制御システムの開発に従事。現在、富士電機株式会社パワエレシステム インダストリー事業本部開発統括部 HMI 開発部主任。





*本誌に記載されている会社名および製品名は、それぞれの会社が所有する
商標または登録商標である場合があります。