

デジタルツイン・シミュレーションによる予測技術の開発

Development of Predictive Technology by Digital Twin Simulation

濱 口 謙 一 技術開発本部総合開発センター制御技術開発部
藤 井 正 和 技術開発本部総合開発センター制御技術開発部 課長

近年、プラントや産業装置のIoT化に大きな注目が集まっている。特に、日々蓄積される稼働データから製品の状態を適切に把握・予測し、より効果的なオペレーションや適切なメンテナンスを実現する技術は、お客さまに製品を長く安心して使っていただく上で非常に重要である。デジタルツイン・シミュレーションは、当社が設計・製造・試験を通じて蓄積してきた物理・化学的知見に基づいて構築した物理モデルと製品の稼働データを融合させることによって、稼働データ単体では捉えることが難しいプロセス特性の把握や、シミュレーションの精度向上が達成できる。開発中の本技術を実際のプラントデータに適用した結果、有効性が確認できたので報告する。

In recent years, the IoT of plants and industrial equipment has attracted much attention. In particular, to use products for a long time it is important to properly ascertain and predict the state of products from accumulated operational data and carry out more effective operations and appropriate maintenance. Digital Twin Simulation combines operational data with physical models that we have built based on physical and chemical knowledge through design, manufacturing, and testing. With this technology, it is possible to ascertain product characteristics that are difficult to capture with data alone and improve simulation accuracy. We applied this technology to actual product data. As a result, we have confirmed its effectiveness.

1. 緒 言

お客さまに製品を安全・安心に長く使用していただくためには、装置の状態を正確に把握・予測し、適切なメンテナンスを行うことが重要である。当社では、MT (Mahalanobis Taguchi) 法をはじめとするデータ解析による予防保全技術⁽¹⁾を開発してきたが、より高精度で物理法則にのっとったプラントの状態の把握と予測を実現するため、デジタルツイン・シミュレーション技術の開発に取り組んでいる。

本稿において、デジタルツイン・シミュレーション技術とは、当社が設計・製造・試験を通じて蓄積してきた物理・化学的知見に基づいて構築した物理モデルと、プラントから日々得られるセンサデータを融合させたシミュレーション技術のことであり、本技術により、従来よりも高精度な予測や、オペレーションの最適化が可能となる。本稿では、本技術の概要と適用検証例を通じた本技術の有効性を紹介し、今後の展望について述べる。

2. デジタルツイン・シミュレーションによる推定・予測

2.1 従来の推定・予測手法と課題

化学プラントや発電プラントなどでは、安全操業に加え、より効率的なオペレーションが求められている。ま

た、大型プラントは停止・再稼働に要する経済的な負荷が大きいため、適切なメンテナンス計画の作成手段も重要になる。これらを実現するためには、プラントの異常や劣化などの状態を正確に推定し、将来の状態を予測する技術が重要となる。

近年、産業装置のIoT (Internet of Things) 化と相まって、運転データを利活用する技術に注目が集まっている。特に、プラントの運転データを基に、対象となるプロセスをモデリングする手法として、機械学習をはじめとする統計的手法が盛んに研究されている。この統計的な手法は、プラントの稼働データさえあれば幅広く適用できるため、汎用性と簡易性の両面で優れており、また、相関関係などのデータ間のつながりを定量的に評価できる利点がある。しかし、統計的なモデリング手法には、次のような課題がある。

- (1) 一般にプロセスの動作条件が変更されると、モデルの予測精度が低下し、しばしば物理的に不可解な予測値をとる。統計的手法によって、広動作領域で高精度のモデルを構築することは難しく、特にプラントが動作したことがない領域での予測は難しい。
- (2) 統計的な手法によってモデリングしているため、モデル内部の計算は物理的意味をもっておらず、プロセス全体の状態を把握することはできない。例え

ば、装置のある特定の圧力といった変数（以下、目的変数）の予測ができて、目的変数以外の変数、すなわち、プロセス全体がどのような挙動をしているのかは不明である。

統計的なモデリング手法は、プロセス内部の物理現象を考慮していないため、ブラックボックスモデリングと呼ばれる。一方、プロセスの物理・化学的な知見に基づいたモデリング手法はホワイトボックスモデリングと呼ばれ、作成されたモデルは物理モデルと呼ばれることが多い。物理モデルは、プロセスの原理・原則に基づいてプラントの挙動が予測でき、定常運転外の挙動も再現していることが多い。また、プラント全体を物理モデリングしている場合は、計算結果からプロセス全体の挙動が理解できる。そのため、物理モデルはプラントや計装制御の設計など、プラントの製造前に活用されることが多い。一方で、プラントの運用が開始され、フィルタなどの経年劣化やそのメンテナンスによって、プロセス自体が徐々に変化し、物理モデルとの乖離が大きくなっていくことから、物理モデルは運用開始後、時間を経るにつれて利用される頻度が減少していく傾向がある。

第1表に統計モデルと物理モデルの比較を示す。

2.2 デジタルツイン・シミュレーション

当社では、ラボレベルの研究やパイロットプラントの設計・試運転を通じて培ってきた物理モデルを、商用プラントの設計時だけでなく、稼働後のオペレーションやメンテナンスを含めたライフサイクル全体で活用するための技術開発を行っている。本稿では、物理モデルを実プラントから得られる日々の運転データと融合して活用する、デジタルツイン・シミュレーション技術を紹介する。第1図にデジタルツイン・シミュレーションのイメージを示す。

以下に、物理モデルと運転データをどのように組み合わせているか、3ステップに分けて解説する。

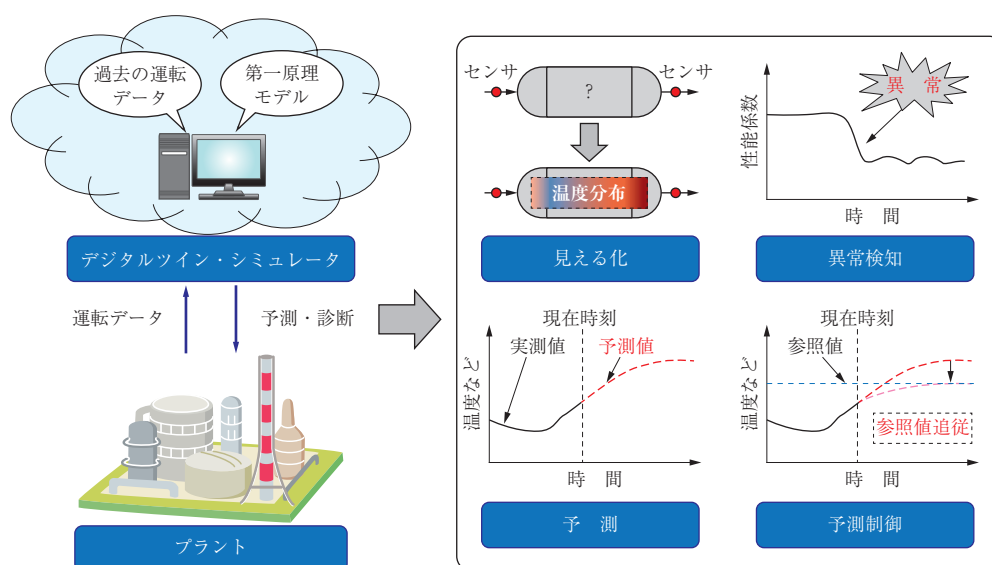
(1) ステップ1：データ同化

シミュレータの動作条件を、実プロセスと同条件に設定して計算を行う。このとき、実プロセスから得られる計測データと、シミュレーション結果には必ず誤差が存在する。この誤差を補正するよう、シミュレータ内の物理係数（例えば、触媒の活性係数や熱交換器の熱伝導係数、ガスタービンの圧縮効率など）を逐次変更していく。この操作のことを一般

第1表 統計モデルと物理モデルの比較

Table 1 Comparison of statistical models and physical ones

項目	統計モデル	物理モデル
特徴	運転データを基に、機械学習などによって作成される。	物理・化学的な知見に基づいて作成される。
モデルに必要な条件	適切なプラントの稼働データが必要になる。	設計者は対象のプロセス現象を熟知している必要がある。
予測精度	・定常運転での予測精度は高い。 ・データの不足した運転領域では、予測精度が低くなりがち。	・未知の動作領域でも、予測精度をある程度維持できる。 ・メンテナンスなどによるプラントの経年変化には対応できず、予測精度が下がっていく。



第1図 デジタルツイン・シミュレーションのイメージ

Fig. 1 Conceptual image of Digital Twin Simulation

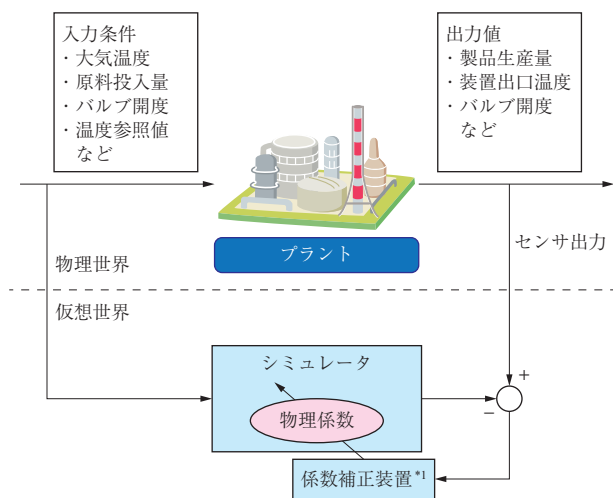
にデータ同化と呼ぶ。第2図にプラントのデータ同化イメージを示す。この操作によって、直接計測することができないプロセス特性をリアルタイムに把握し、かつシミュレータによってセンサの配置していない箇所を含めて装置全体の内部状態が可視化できる。

(2) ステップ2：装置特性の解析

ステップ1で更新された物理係数を解析することで、装置の劣化状況を把握できる。特に、時間経過に従った物理係数の解析を通じて、装置の劣化の進み具合、触媒の交換などのメンテナンス作業によって装置性能がどの程度復旧するか、といった知見が獲得できる。第3図に触媒のモニタリングイメージを示す。生のセンサデータだけでなく、プラント固有の劣化状態を定量的に管理することで、プラントの状態をプロセス現象の原理・原則に則して把握・管理できる。


(3) ステップ3：シミュレーションによる予測

ステップ2で解析した物理係数をシミュレーション



(注) *1：入出力関係が実センサと一致するように、シミュレータ内の物理係数を逐次調整

第2図 プラントのデータ同化イメージ
Fig. 2 Conceptual image of plant data assimilation



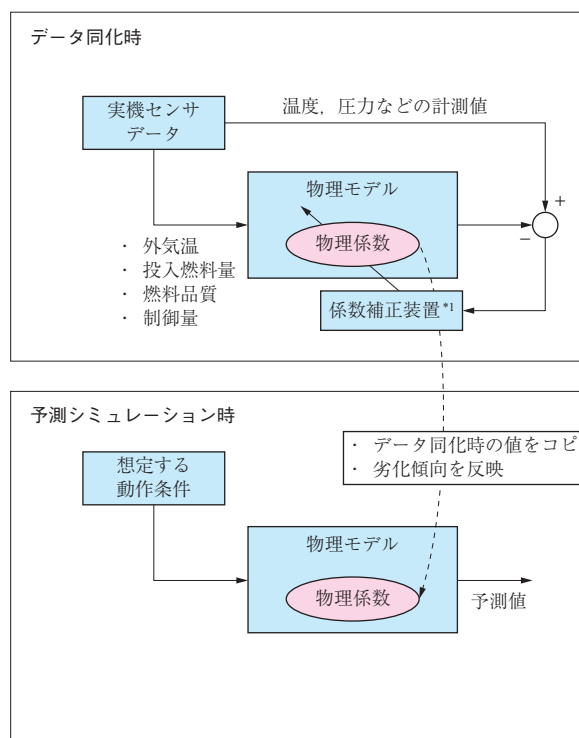
第3図 触媒のモニタリングイメージ
Fig. 3 Conceptual image of monitoring catalyst performance

に反映させることによって、さまざまな動作条件と時間スケールで将来のプラントの状態が予測できる。例えば、ボイラの燃料投入量を変更した場合、プロセス全体がどのように変化するかといった数分～数時間単位の動的なシミュレーションから、化学プラントの触媒の劣化速度が今後継続した場合、数か月先の生成物の生産効率がどう推移するか、といったシミュレーションが可能になる。触媒などの経年劣化による生産効率の低下や、メンテナンスによる生産効率の回復量を考慮することで、経済性を考慮したメンテナンス計画が可能となる。ステップ1のデータ同化を含めた予測シミュレーションを第4図に示す。

3. 検証

検証のため、デジタルツイン・シミュレーション技術を、発電用ガスタービンエンジンに適用した。ここでは、あらかじめ計測しておいた定常運転時の実測値データを用いて、ガスタービンエンジンの再現シミュレーションを行い、このときの圧縮機出口圧力の計算精度と実測値の誤差を評価する。

本検証で使用するガスタービンエンジンモデルは、動作



(注) *1：入出力関係が実センサと一致するように、シミュレータ内の物理係数を逐次調整

第4図 予測シミュレーション
Fig. 4 Predictive simulation

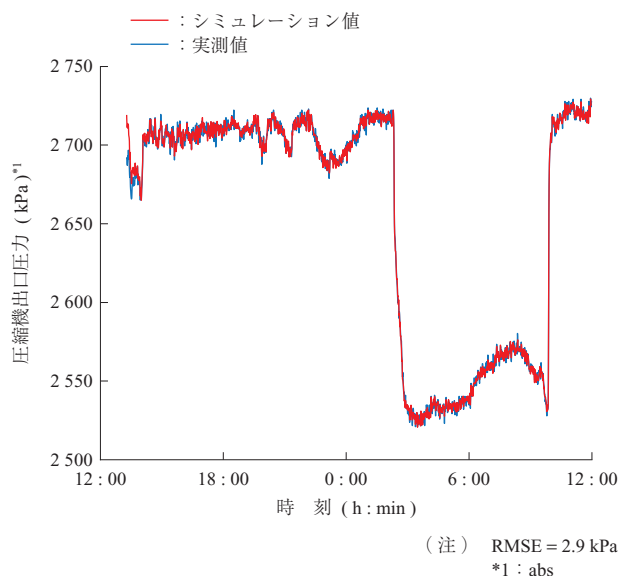
条件（入力値）として、吸気温度、圧力、投入燃料量・燃料品質、バルブ開度などをシミュレータに設定する。

実プラントと同様の動作条件で 24 時間分のシミュレーションを行ったときのシミュレーション値と実測値を第 5 図に示す。シミュレーション値と実測値は全体的な変動の傾向は合致しているものの、両者の誤差は RMSE（Root Mean Square Error：平均平方二乗誤差）で 139.8 kPa と予測精度は低い。

本シミュレータに対し、2.2 節のステップ 1 で示したデータ同化を行う。第 5 図の計測データの 24 時間前から 24 時間分の各部の温度・圧力・回転数など計 7 変数の計測データを用いて、エンジン内部の圧縮効率などの物理係数を変化させて、物理モデルの出力値を実測値に適合させた。なお、ガスタービンは非常に強い非線形性をもつため、本検証では非線形カルマンフィルタをデータ同化アルゴリズムに採用した⁽²⁾。データ同化時の圧縮機出口圧力のシミュレーション値と実測値を第 6 図に示す。両者の線がほぼ重なっており、シミュレーション値（物理モデルの出力）が実測値と合致していることが分かる。

本検証では、データ同化区間が 1 日と短いため、圧縮機の劣化などの現象をデータ同化結果から確認することはできなかった。しかし、データ同化を行ったことによるシミュレーションの精度の向上が期待できる。

データ同化処理で得られた物理係数を使用して、第 5 図と同様の時間・動作条件でシミュレーションを行った。このときのデジタルツイン・シミュレーションの結果を第 7 図に示す。予測誤差が RMSE で 16.1 kPa と、第 5 図




第 6 図 データ同化時のシミュレーション値と実測値
Fig. 6 Simulated value (red) and measured one (blue) when assimilating data

のシミュレーション時に比べると誤差が 1/10 程度に軽減していることが確認できた。


4. 結 言

本稿では、デジタルツイン・シミュレーション技術の概要を解説し、実際のガスタービンエンジンの計測値と物理モデルを用いたデータ同化を適用した予測シミュレーションによって、シミュレーション精度が大幅に改善することを示した。

本技術は、プラントの稼働データと物理モデルを融合させることによって、データ単体では捉えることが難しい劣



第 5 図 シミュレーション値と実測値
Fig. 5 Simulated value (red) and measured one (blue)



第 7 図 デジタルツイン・シミュレーション結果
Fig. 7 Result of the Digital Twin Simulation

化などの特性の把握や、シミュレーションの精度向上が達成できる。本検証では予測シミュレーションのみを行ったが、最適化技術と組み合わせることで、プラント稼働後のオペレーション最適化やメンテナンス計画の高度化、制御ロジックの高度化の実現を目指している。

IoT で得られたプラントの稼働データを、従来のデータに基づいた統計的アプローチに加え、当社が蓄積してきた物理モデルを組み合わせた本技術によって、当社製品のライフサイクル全般にわたって、お客さまへのサービスの提

供に取り組んでいく。

参 考 文 献

- (1) 袖子田志保, 木村麻衣, 鈴木由宇, 近藤智佳子 : データ解析による予防保全技術の開発, IHI 技報, Vol. 54, No. 2, 2014年6月, pp. 26 - 31
- (2) 藤井正和 : カルマンフィルタを用いた複数ロボットによる協調位置推定, 計測と制御, Vol. 56, No. 9, 2017年9月, pp. 679 - 682