

富士電機のアナリティクス・AI

Fuji Electric's Analytics and AI

浅野 貴正 ASANO, Takamasa

渡辺 拓也 WATANABE, Takuya

白木 崇志 SHIRAKI, Takashi

近年、企業の DX への取組みが加速している。DX 推進に必要なデジタル技術の中で、AI はその中核を担う技術である。富士電機のアナリティクス・AI は、認識・診断・予測・最適化を行う統計解析・機械学習技術の総称であり、富士電機はその要素技術開発に取り組んでいる。認識技術としてはディープラーニング技術を用いた画像認識 AI を適用し、診断技術としては教師なし学習の代表的な 5 種類のアルゴリズムを評価し、予測技術としてはフィルタ法やラッパー法に着目した。最適化技術としては、複数設備の状態を同時にチェックするデータ不整合検出技術を開発した。

In recent years, companies have been accelerating their efforts to promote DX. AI is one of the core digital technologies needed to promote DX. Fuji Electric has developed the basic technologies of Analytics and AI, which is a collective term for statistical analysis and machine learning technologies used for recognition, diagnosis, prediction, and optimization. For recognition technology, we developed image recognition AI using deep learning; for diagnosis technology, we evaluated five typical algorithms of unsupervised learning; for prediction technology, we focused on filter and wrapper methods; for optimization technology, we have developed a data inconsistency detection technology that checks multiple equipment statuses simultaneously.

1 まえがき

企業のビジネス環境の激しい変化に対応し、データとデジタル技術を活用して、製品やサービスに対して競争上の優位性を持たせる DX (デジタルトランスフォーメーション: Digital Transformation) は、企業経営に必須となっている。また、近年の IoT (Internet of Things) 技術の普及により、多種多様で大量のデータが容易に収集できるようになっている。さらに、AI (Artificial Intelligence) 技術の発展により、大量データを利活用した新しい顧客価値の創出や社会課題の解決の期待が高まっている。企業の DX 推進に必要なデジタル技術の中で、AI はその中核を担う技術である。これまで、富士電機では、アナリティクス・AI の開発を通じて、産業プラントや社会インフラ分野におけるさまざまな課題を解決してきた。

具体的に述べると、FA (Factory Automation) 分野では、製造設備の保全管理や製造品質管理の高度化の要求に応え、独自の異常診断技術として、バッチプロセス向け MSPC (Multivariate Statistical Process Control: 多変量統計的プロセス管理) を開発し、設備の予防保全や不良品率の低減に貢献してきた。時々刻々と変化するエネルギー需給の分野では、高精度予測の要求に応え、ニューラルネットワークや JIT (Just-In-Time) 予測を独自に改良し、将来のエネルギー需要の予測に適用している。さらに、数理計画法やメタヒューリスティクスの最適化技術と組み合わせ、プラント機器の運用計画を自動的に立案し、燃料コストと CO₂ の削減に貢献している。また、AI のブラックボックス問題に対して“説明できる AI”の開発を行ってきた。ニューラルネットワーク構造を工夫して入出力の相関関係を可視化する独自の構造化ディープラーニング (DL) 技術を開発し、これまで AI の適用が難しかった

安全性・信頼性が必要な分野への適用拡大を目指している。

2 アナリティクス・AI の全体像

富士電機のアナリティクス・AI とは、認識・診断・予測・最適化を行うための、統計解析・機械学習技術の総称である (図 1)。アナリティクス・AI では、現場の状況を認識し、事象の発生原因を診断する。そして、将来の状態

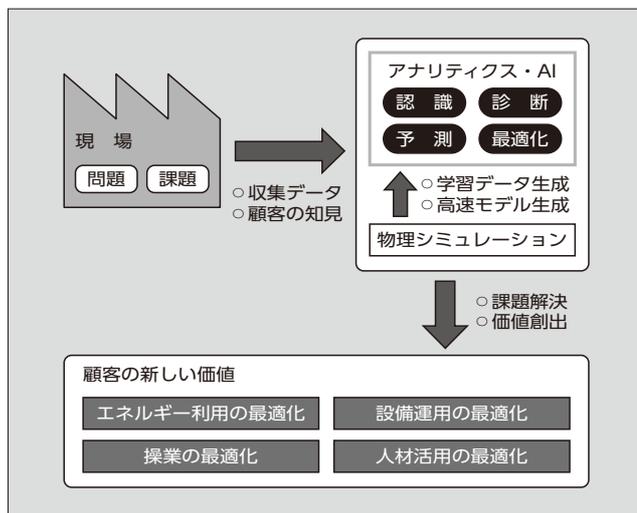


図 1 富士電機のアナリティクス・AI の全体像

〈注 1〉ディープラーニング (DL): DL は、Deep Learning の略である。ディープラーニングとは、人の脳神経を模倣したニューラルネットワークを多層化して計算機で学習する方法である。主に、画像認識、言語認識、予測などに応用される AI のアルゴリズムの一つである。

を予測した上で最適化を行い、顧客の新しい価値を創出する。

2.1 認識技術

認識では、文章や画像データなどに対して、独自の前処理技術と最新の DL 技術を適用し、設備保全の省力化（“設備保全の技術伝承・情報共有を推進するためのテキスト認識技術”、174 ページ参照）や、製品外観検査の自動化などを実現する。

2.2 診断技術

診断では、製造プロセスデータなどに対して、その特性が正規分布に従う対象には、適用実績の豊富な MSPC を、より複雑な特性を持つ対象には、新しい機械学習手法を適用し、製造プロセスの異常の予兆検知や原因診断などを実現する⁽¹⁾。

2.3 予測技術

予測では、プラント運用データなどに対して、データが豊富な対象には、複雑なモデル化ができる構造化 DL を、少ない対象には、少量データでもモデル化ができる JIT 予測を適用し、将来のプラント状態を予測することで運転操作の支援を実現する⁽¹⁾。

2.4 最適化技術

最適化では、発電機やボイラなどのプラント機器の数が比較的少ない場合や計画期間が短い場合には数理計画法を、機器数が多い場合や計画期間が長い場合にはメタヒューリスティクスを適用し、人間の運用よりも効率的なプラントの運転を実現する⁽¹⁾。

また、富士電機のシミュレーション技術とアナリティクス・AI を融合し、デジタルツインの実現に向けたモデル構築技術として、シミュレーション応用技術を開発している。

③ アナリティクス・AI の紹介

3.1 認識技術

近年の AI 技術の急速な進歩により、従来のルールベース手法では代替が困難であった人による高度な作業の自動化に、DL 技術をはじめとした AI 技術の適用が始まっている。

富士電機では DL 技術を産業分野に適用するため、学習データの不足に対応した前処理技術、少量の正常データだけを使った学習による異常検知技術、AI 判断の可視化技術などの要素技術を開発してきた。次に、DL 技術を用いた画像認識 AI の適用事例として、社内工場における半導体ウェーハ（ウェーハ）の外観検査の自動化について述べる。

(1) ウェーハの外観検査の目的と課題

富士電機は、さまざまなパワー半導体製品を製造している。これらの製品はウェーハから、酸化工程、パターン形成工程、配線形成工程、チップ化工程、実装・封止工程などを経て製造される。各工程において、種々の不良が発生するため、工程間で外観検査を行い、不良箇所を検出するため画像を撮影している。その画像を異常モードごとに分類・計数し、各異常モードの発生件数の傾向から、異常の原因となった工程を特定し、プロセスの改善に役立てている（図 2）。従来は、撮影した画像を現場の技術者が目視で分類していたため、分類作業に多くの時間を要していた。また、技術者によって分類の基準が異なるため属人性が高いという課題があった。そこで、撮影画像の分類に画像認識 AI を適用することで、分類・計数作業の省力化とスループットの向上、属人性の排除を図った。

(2) 分類結果の可視化

撮影画像を必要に応じてホワイトバランス補正、明るさの正規化、データ拡張などの前処理をした後、画像認識 AI で異常モードごとに分類し、その結果を可視化する。図 3 に分類結果の可視化例を示す。図 3 (a) は各ロットについてウェーハごとの異常が見つかった撮影画像の枚数をプロットしたグラフであり、どのロットでウェーハに異常が多く発生しているか確認することができる。図 3 (b) は各異

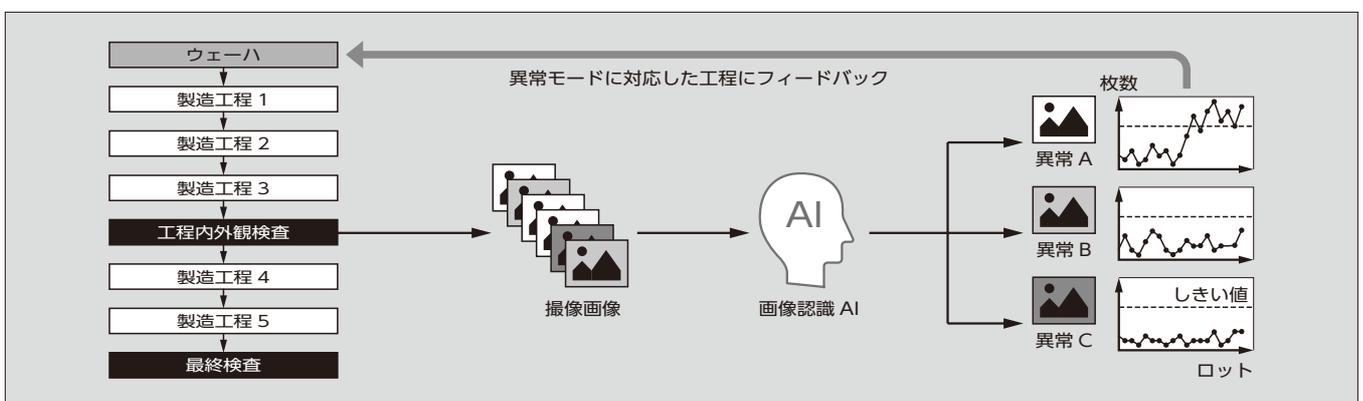


図 2 ウェーハの外観検査への画像認識 AI の適用

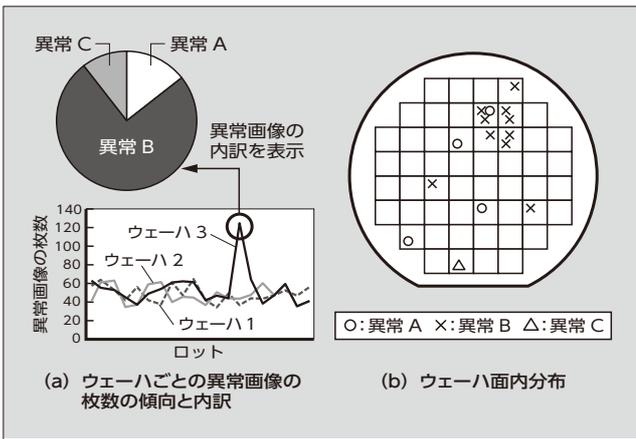


図3 画像認識AIによる分類結果の可視化例

常がウェーハ面内のどの位置で発生しているか可視化した例であり、面内で均一に発生しているのか、特定の箇所に集中して発生しているのかを確認できる。このように、さまざまな角度から異常の発生傾向を解析し、改善が必要な製造プロセスを特定することが可能となる。

今後は、本システムの運用を通して、アナリティクス・AIの課題の一つであるコンセプトドリフト^(注2)の検知・対策技術の開発を行う予定である。

3.2 診断技術

AI技術を製造工程の異常診断に適用することによって、品質向上や歩留まり改善に貢献している。富士電機では化学プロセス分野で実績のあるMSPCで多くの経験がある⁽³⁾⁽⁴⁾。また、複雑な特性を持つ対象でも精度よく診断する機械学習や、診断根拠を説明する機能を開発してきた⁽¹⁾。

複雑な特性に対する診断は、さまざまな適用対象に対しての性能評価に基づいて、適切な手法を選択する必要がある。実際の製造工程では異常発生がそれほど多くないため、富士電機では、学習時に異常データが不要な教師なし学習に注力し、さまざまな手法を試行している。

本節では、次に示す教師なし学習の代表的な5種類のアルゴリズムを評価した結果について述べる。

- (a) OCSVM (One Class Support Vector Machine) : カーネルと呼ばれる非線形関数を用いて診断
- (b) IF (Isolation Forest) : 決定木と呼ばれる if-then ルールをベースにした診断
- (c) LOF (Local Outlier Factor) : 正常データからの距離で診断
- (d) iNEE (Isolation using nearest neighbor ensembles) : IFとLOFを融合した診断
- (e) EnsKnn (Ensemble K-Nearest Neighbor Algorithm) : 複数の類似データから診断

〈注2〉コンセプトドリフト：AIモデルが推論しようとしている対象の統計的特性が、さまざまな原因で時間の経過とともに変化するをいう。

今回、ベンチマークデータとして、10セットの実データを用意した。主として製造工程で計測される電力、温度、圧力などからなる時系列データである。正常期間のデータを学習して診断モデルを構築し、検証対象期間のデータの正常・異常が診断できるかどうかを検証した。図4は、機械学習手法の違いによるF1スコアと呼ばれる診断性能の比較である。F1スコアは適合率（正と判断した中で正しい判断をした率）と再現率（実際に正の中で正しい判断をした率）の調和平均で、1に近いほど診断性能が高い。診断性能が最良の手法は、例えば図4の結果ではデータセットD01に対してはLOFが、データセットD02に対してはEnsKnnであり、データセットごとに最良な手法が異なる。図5は、機械学習手法ごとの診断時間を比較したグラフである。LOFやEnsKnnは、診断性能は高いが診断時間が長い。

今回の結果から、データセットごとに最良の手法が異なること、手法により診断時間が異なることを確認できた。F1スコアや診断時間を使えば、診断対象の要求仕様に合わせて適切な手法が選択できる。また、これら手法をデータサイエンティスト以外のエンジニアでも簡単に扱えるようにツール化していく予定である。

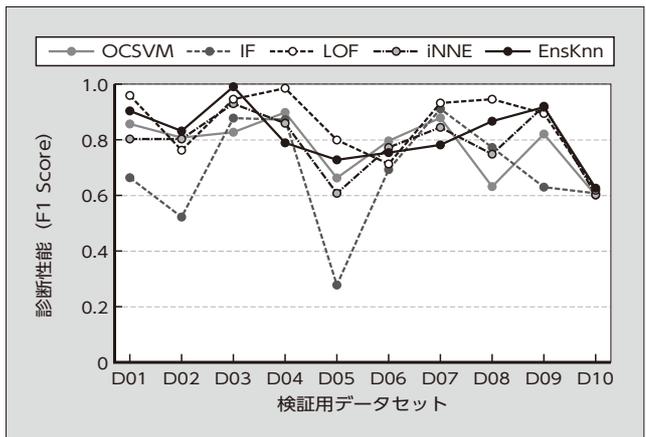


図4 機械学習手法による診断性能の比較

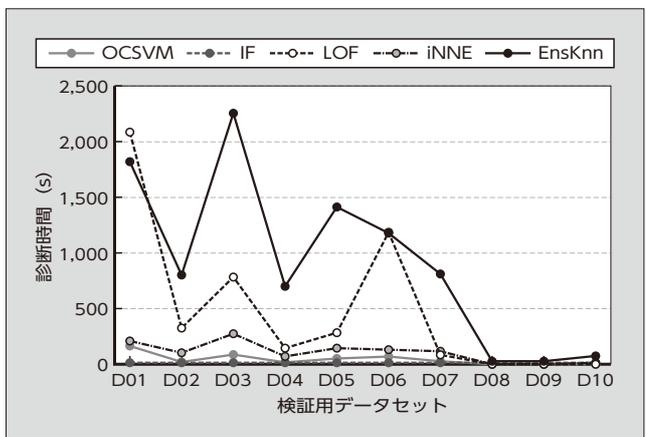


図5 機械学習手法による診断時間の比較

3.3 予測技術

富士電機では、プラントの運転操作を支援するため、エネルギー需要や品質を予測する技術を開発している。学習データが少ない場合でも予測できる JIT 予測や、予測結果が説明できる構造化 DL など、特徴ある予測モデルを開発してきている。予測モデル自体の開発の他に、どの入力変数を選択するのも精度の良い予測モデルの生成には重要である。通常、入力変数の選択では、データサイエンティストが予測対象に関する知識を得ながら試行錯誤を繰り返すため、検討に数日から数か月単位で時間を要するという問題があった。そこで、例えば JIT 予測に関しては、この試行錯誤を減らすため、変数重要度を用いた独自の変数選択法を開発してきている。

さらに、さまざまな機械学習に適用できる汎用的な変数選択法であるフィルタ法、およびラッパー法に着目した(図6)。フィルタ法は、変数ごとに計った重要度が一定値以上であれば入力変数として採用する。ラッパー法は、予測誤差の変化から最も予測精度が高い入力変数の組合せを探す。

それぞれの方法の有効性を検証するため、ベンチマークデータとして、製造工程の数時間先の温度を予測する問題を用意した。入力変数の候補は、計測された全 429 種類のデータである。予測手法は、多くの入力変数を取り扱うことが容易な PLS (Partial Least Squares) 回帰を用いた。

表1に予測結果を示す。フィルタ法とラッパー法のいずれも、変数選択をしない方法と比較し、少ない入力変数で平均誤差を小さくすることができた。さらにラッパー法はフィルタ法よりも平均誤差が小さかった。

今後は、この変数選択技術をプラントの予測支援などの実製品への適用を目指すとともに、異常診断の学習ツール

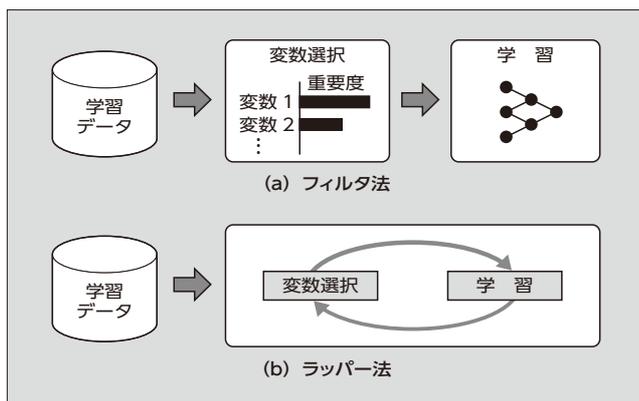


図6 フィルタ法とラッパー法の概念図

表1 変数選択法による予測誤差の変化

	入力変数の数	平均の予測誤差
変数選択なし	429	4.4%
フィルタ法	23	3.7%
ラッパー法	61	3.1%

にも適用する予定である。

3.4 最適化技術

これまで、EMS (Energy Management System) に適用してきた最適化技術では、工場やビルのユーティリティ設備をプラントモデルとして作成し、燃料コストやCO₂が最小となる最適な設備運用(最適な組合せ)を求める。求めた最適解を基に、オペレーターへのガイダンス提示やユーティリティ設備の自動制御を行っている。

プラントの最適運用を求めるためには、まずプラントモデルを混合整数計画問題として定式化する。これとともに、予測機能による需要予測やオペレーターによる運転計画、設備特性などさまざまな入力条件や制約条件を与える。この条件を満たした上で数理計画法により最適解を求める。また、大規模な電力系統や数式化できないモデルを含む電力系統の場合、PSO (Particle Swarm Optimization) などのメタヒューリスティクスを適用し、最適解を求めている。

最適化計算の際に、入力条件に矛盾があったり、設定を忘れてしまうと制約条件に違反することになり、計算が異常終了してしまう。あるいは、計算自体は問題なく終了しても省エネルギー(省エネ)効果が過大に算出されるなど、計算結果が異常となることもある。このような場合、システムエンジニアが全ての入力条件を精査し、エラー発生箇所を突き止める必要がある。また、エラーは1か所とは限らないため、繰り返しチェックを行う必要があり、エンジニアリングの工数が増えてしまうという問題があった(図7)。

そこで、計算の異常終了や計算結果に異常があった際に、不整合なデータを自動で特定してデータの修正箇所を示すことで、この問題を解決している(図8)。さらに、どの制約条件により解なしとなったのかを特定して、異常終了の原因を把握できるようにするため、次に示すような工夫を行っている。

(1) 設備個別の制約チェック

燃料の投入量の上下限、出力の上下限などのさまざまな制約条件がある設備の最適化において、上下限を超える運

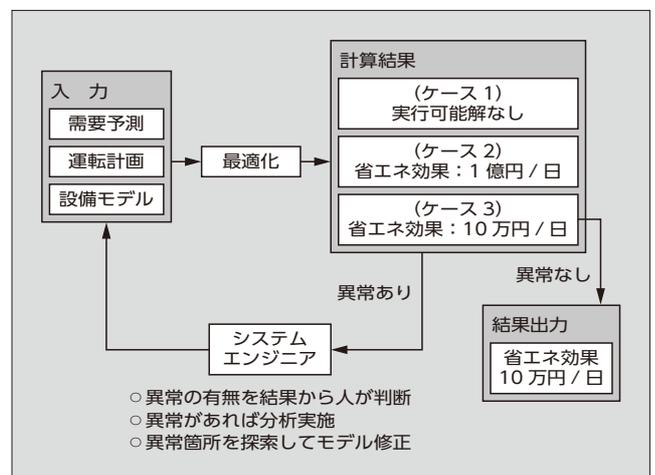


図7 従来のエンジニアリング

特集 富士電機のDX(デジタルトランスフォーメーション)

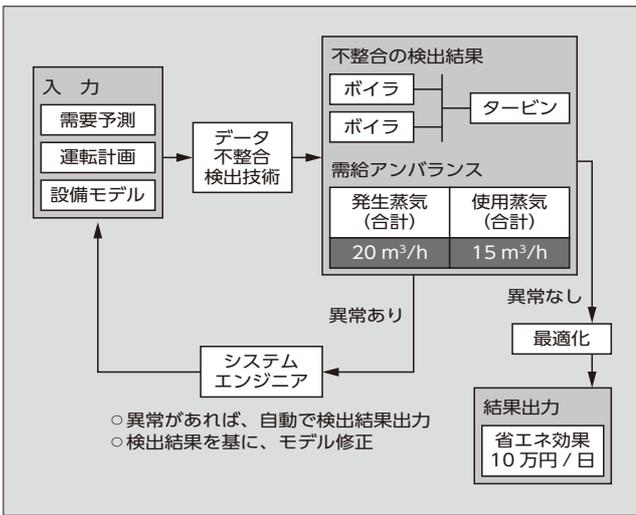


図8 データ不整合検出技術を適用したエンジニアリング

用計画の設定や、上限と下限を入れ替えた間違った設定などの計算ができない設定になっていると異常終了となる。異常終了時には、制約条件の有効と無効を切り替えて再計算し、計算が可能となったときに無効とした制約条件が異常となっている原因であると判断する。

(2) 設備間の制約チェック

複数の設備間で制約違反があった場合、前述した設備ごとの制約条件のチェックでは判断ができないことがある。例えば、図9に示すように、設備Aと設備Bの出力が設備Cの入力となるエネルギーの需要と供給の関係(需給制約)があるとす。例えば、停止指示を設備Aと設備Bに、出力指示を設備Cに与えた場合、設備Aや設備B、設備Cを個別にチェックしてもそれぞれの設備計画に制約違反はないが、プラント全体では制約違反となるため異常終了となる。このように一見正常に見えても、設備を組み合わせたエネルギーネットワークモデルとした際に異常となるような場合、通常の数値チェックだけでは異常検知は困難である。そこで、エネルギーネットワークモデルを解析して需給制約の有効や無効を切り替えることにより異常となっている需給制約を検索し、さらに複数設備の状

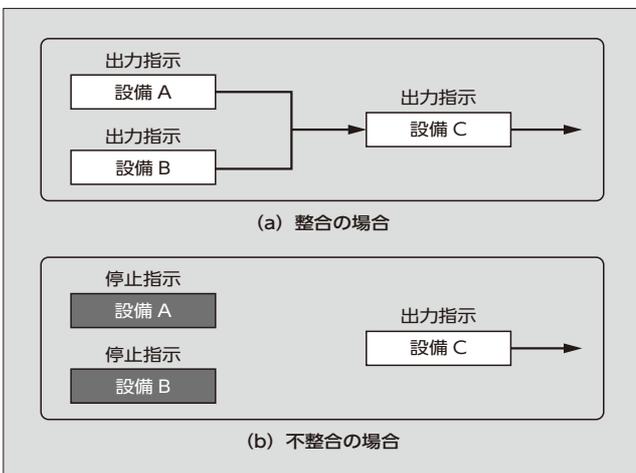


図9 設備間制約における整合・不整合の例

態を同時にチェックするデータ不整合検出技術を開発して活用している。

従来、設備の入替えや構成の変更などを行う際にシミュレーションを行うと異常終了となった原因を見つけ出すにはエネルギーネットワークモデルや最適化技術を熟知している必要があった。しかし、本データ不整合検出技術によって、専門知識がなくてもエンジニアリング時のデータ解析作業の短縮、およびユーザーによるメンテナンスの支援が可能となる。

3.5 デジタルツインを実現するためのシミュレーション技術

デジタルツインとは、現実の設備や製品の機能や動作をデジタル空間上に再現し、リアル空間上の稼働データとリアルタイムに連携する技術のことである。デジタルツインを用いることで、設備や製品の現在や将来の稼働状態をリアルタイムで把握することができ、設備の予防保全によるメンテナンスコストの低減や、最適な運転状態を維持することによる省エネなどの顧客価値の創出が可能となる。

富士電機では、構造設計を中心としたシミュレーション技術を開発してきた。デジタル端末上で行うさまざまな制御条件や環境条件での物理的動作のシミュレーションにアナリティクス・AIを融合することで、これまでの製品設計だけでなく、試験や保守を含めた製品ライフサイクルの効率化、さらにはデジタルツインの実現への応用も期待できる。

本節では、そのデジタルツインの実現を見据えた技術として、シミュレーションの精度向上のためのパラメータ同定技術や、従来シミュレーションのリアルタイム化、すなわち高速化を可能にする代理モデル変換技術などのシミュレーション技術について述べる。

(1) パラメータ同定技術

シミュレーションには、設計情報により、値が自明なパラメータ群(寸法など)と、値が不明なパラメータ群(劣化状態など)がある。特に値が不明なパラメータ群は、実現象をシミュレーションする上で、精度低下の一つの要因となっていた。

そこで、AI技術の一つである最適化技術を適用し、これらのパラメータ群を最適値に同定する技術を開発した。シミュレーションの出力結果と実システムの収集データとの誤差が最小となるようパラメータ群を同定することで、シミュレーションの精度が向上した。

(2) 代理モデル変換技術

シミュレーションでは、膨大な量の計算を実行するので長い時間がかかることがある。その場合、試験や保守への応用に必要な安定的なリアルタイム性能〔常に定められた時間内(おおむね5s以内)で計算が終了する性能〕を満足することはできなかった。

そこで、機械学習技術と最適化技術を適用し、通常のシミュレーションよりも短時間で計算が終了する代理モデルに変換する技術を開発した。

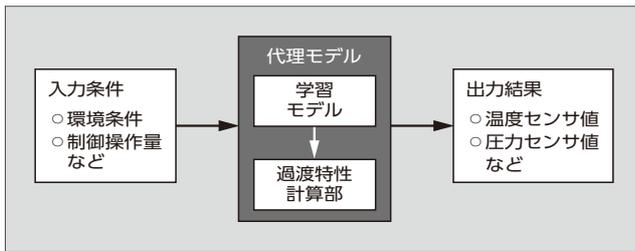


図10 代理モデルの構成

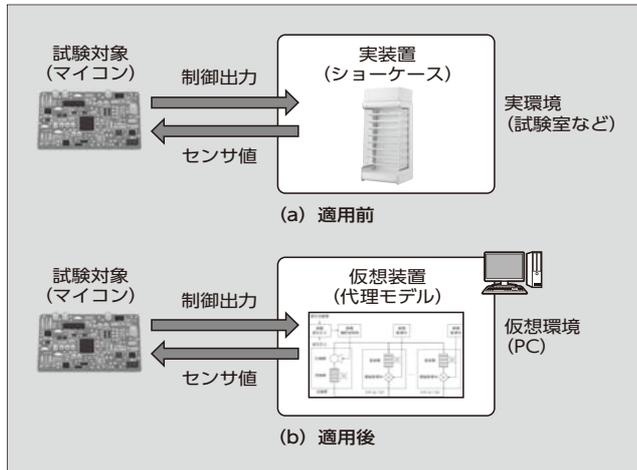


図11 ショーケース用 HILS の構成

図10に上述した代理モデルの構成を示す。代理モデルは、定常特性を表す学習モデルと過渡特性を表す計算部より構成される。学習モデルは、シミュレーションの入力パラメータ（環境条件や制御操作量など）を多条件で動かして出力結果（温度センサ値など）を得て学習データを作った後、ディープラーニングなどの機械学習を使って生成する。過渡特性計算部は、時定数などのパラメータを持つ方程式である。最適化技術によってモデルの出力と実際のデータの誤差が最小となるように、それらのパラメータの最適値を決定する。

この代理モデルにより、計算時間が不安定で低速なシミュレーション（計算時間：10s～5min）を高速化（計算時間：1s以内）することができた。

続いて、本技術の適用事例として、ショーケース用のコントローラの動作を実装置のショーケースなしで効率的に検証することを目的としたHILS^(注3)の構成例を示す。

図11にショーケース用HILSの構成を示す。ショーケース庫内の温度などの各所のセンサ値を予測する代理モデルを生成して仮想装置としてPC上に組み込む。そのPCと制御マイコンとを接続することで制御マイコンの検証ができるようにした。環境試験室の構築や試験条件の切り替えの際に大きな費用や作業工数が掛かっていた実装置と実環

〈注3〉HILS：Hardware in the Loop Simulationの略である。制御対象の挙動をPC中に再現する検証用シミュレータのことである。

境を用いた試験が不要になっただけでなく、夏季や冬季などの季節条件や、さまざまな動作条件や故障条件の全てを再現できるようになった。これにより、今後のいっそうの省エネ性能を持つショーケースや、環境に配慮した冷媒を使ったショーケースの早期開発が可能となる。

4 あとがき

本稿では、富士電機のDXの中核となるアナリティクス・AIについて述べた。

アナリティクス・AIの適用拡大のためには、構想・PoC（Proof of Concept：概念実証）・実装・運用といったAI開発の各プロセスにおける要素技術の拡充が必要である。

今後も、アナリティクス・AIの要素技術の開発の加速やデジタルツインの実現によって新しい顧客価値の創出や社会課題の解決に貢献していく所存である。

参考文献

- (1) 飯坂達也ほか. 価値創出のコアとなるアナリティクス・AI. 富士電機技報. 2018, vol.91, no.3, p.169-174.
- (2) 石河範明. “富士電機における画像認識AIの適用事例”. 電気学会D部門大会. 2021, S7-5.
- (3) 飯坂達也ほか. “多変量統計的プロセス管理技術を用いた火力発電プラントの異常検知”. 電気学会B部門大会. 2010, 353.
- (4) 村上賢哉ほか. “バッチプロセス向けMSPCにおける新しい異常判定方式”. 電気学会C部門大会. 2017, GS7-3.
- (5) 石橋直人ほか. デマンドレスポンスを考慮した需要予測へのJITモデリングの適用. 電気学会論文誌B（電力・エネルギー部門誌）. 2014, vol.134, no.1, p.24-31.



浅野 貴正

センシング技術、画像処理・画像認識技術の研究開発に従事。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デジタルプラットフォームセンター AI 研究部マネージャー。電気学会会員、人工知能学会会員。



渡辺 拓也

数値アルゴリズムを利用したエネルギーマネジメントに関する研究開発に従事。現在、富士電機技術開発本部デジタルイノベーション研究所デジタルプラットフォームセンター AI 研究部主任。電気学会会員。



白木 崇志

シミュレーションとAIの応用技術の研究開発に従事。現在、富士電機技術開発本部デジタルイノベーション研究所デジタルプラットフォームセンター AI 研究部主任。



*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。