

プラントエンジニアリング 計測・制御分野における AI・ビッグデータ活用

Instrumental and Control Application Developments Based on AI and Big Data in Plant Engineering

廣田 美晴 HIROTA Yoshiharu JFE エンジニアリング DX 本部 制御技術センター フェロー
原山 昌巳 HARAYAMA Masami JFE エンジニアリング DX 本部 制御技術センター フェロー
中尾 展行 NAKAO Nobuyuki JFE エンジニアリング DX 本部 制御技術センター エネルギー制御部 第四設計室

要旨

近年、AI・ビッグデータを活用することにより、従来技術では得ることが困難であった現象・対象の数値予測や数式モデルを、広義の機械学習により入手できるようになってきている。JFE エンジニアリングでは、2014 年に納入プラントの操業データ蓄積の仕組みを立ち上げ、その蓄積データを利活用することにより、プラント等の制御健全性評価や操業異常診断システム等の基盤技術開発を行ってきた。本稿では、至近の開発事例として、計測分野では、画像解析技術を応用したバイオマス発電燃料の水分・性状のオンライン計測を、制御分野では、深層学習モデル（ニューラル状態空間モデル）を用いた非線形モデル予測制御をバイオマス発電設備送電端効率向上に適用した事例について報告する。

Abstract:

Recent technology developments of AI and Big Data have made it possible to use machine learning to obtain predictive models or mathematical models of phenomena that were difficult to achieve with conventional technologies. At JFE Engineering Co., a system for accumulating operational data from plants was established in 2014. By utilizing this accumulated data, fundamental technologies such as plant control health evaluation and anomaly diagnosis systems have been developed. In this paper, recent development examples are described: in the field of measurement, online measurement of moisture and properties of biomass power generation fuel using image analysis technique, and in the field of control, non-linear model predictive control for improving biomass power generation efficiency using a machine learning neural state space model.

1. はじめに

近年、多様で膨大な量のデータ（Big Data）を使った深層学習モデルに基づく人工知能（Artificial Intelligence: AI）システムは広い応用範囲で大きな成果¹⁾をあげており、特に最近では、大規模言語モデルによる生成 AI が目覚ましい性能進化とともに一般生活の中にも浸透する状況となってきている。

そのような中で、従来、対象の理論数値（第一原理）モデルをベースに考えられてきたプラント設備における計測・制御分野においても、AI 利用により作成されたモデルを用いた計測・制御への適用成果報告²⁾がみられるようになってきた。ここでは、理論モデル構築が難しい対象について、大量の実データを利用し、多層パーセプトロンモデル等に機械学習を施すことにより、理論モデルと同等な特性を有する

モデルを作成・代替利用することが可能となっている。

当社においても、2014 年より自社納入プラント設備（廃棄物焼却炉、太陽光発電設備）のプロセスデータをすべて蓄積するビッグデータサーバを構築し、実運転データの収集と社内提供を開始した³⁾。当初は、納入プラント制御ループ健全性のオフライン確認や、太陽光発電設備の発電量予測に基づく状態診断など、蓄積データの単純利活用が中心であった。その後、2016～19 年には、ビッグデータサーバのクラウド化を経て、対象の追加（バイオマス発電設備）を含むデータ蓄積量の拡大に伴い、さらに高度なデータ利活用を展開した。具体的には、バイオマス発電設備の負荷低減を目的とした、データベース制御パラメータの実データによる最適化や、外れ値検知、機械学習による正常モデルに基づくプロセス異常診断システム開発等、種々の基盤技術開発を行ってきた。また、計測への応用では、特殊計測画像データを対象に技術開発を進め、2017～18 年には漏洩磁束センサ画像によるパイプライン内外面腐食定量計測手

2025 年 3 月 12 日受付

法を開発・実用化し、その後 2019～20 年にも腐食定量計測の精度を向上させる手法を開発してきた。

本稿では、至近の開発例として、計測分野から「バイオマス燃料性状のオンライン計測」と、制御分野から「バイオマス発電プラントの効率向上に向けた機械学習モデル予測制御系の適用」について報告する。

2. バイオマス燃料性状のオンライン計測

バイオマス発電の主要な燃料の一つに、パーム椰子殻 (Palm Kernel Shell: PKS) がある。PKS は、パーム椰子の果実からパーム油を搾った後の種子殻 (径 10 mm 前後) であり、海外から輸入される。PKS にはテネラ種とデュラ種があり、殻の厚みやヒゲの多少等の外観、乾燥燃焼時に発生する熱量等が異なる。PKS は運搬・保管等の過程で雨水等により水分を含むため、PKS の燃焼熱の一部は水が水蒸気になるための気化熱として奪われる。したがって、ボイラ火炉燃焼を安定させ発電出力を維持するためには、燃料の水分と種類をオンラインで把握し、火炉投入重量を調整することが重要である。また、燃料の粒度も燃焼状態の制御のための重要なパラメータとなりうる。

そこで、PKS の燃料性状 (水分/種類/粒度) をオンライン計測するセンサを開発することにした。

2.1 燃料性状センサの構成と水分計測原理

燃料性状センサは、近赤外 2 波長の分光ラインセンサカメラと近赤外 2 波長 (1 200 nm, 1 450 nm) の LED 照明で構成される (図 1)。

ラインセンサカメラは、内部のビームスプリッタとプリズム分光器により 2 チャンネルの異なる分光特性を持つ 1 ライン画像の同軸撮像が可能である。1 200 nm の LED 照明は CH1 の分光特性と重なり、1 450 nm の LED 照明は CH2 の分光特性と重なるため、CH1 と CH2 からそれぞれ 1 200 nm, 1 450 nm の 1 ライン画像 (1 024 画素) を同時に取得できる。撮像視野サイズは、カメラレンズから 500 mm の距離で約 200 mm (分解能: 0.2 mm/画素) である。PKS はラインセンサと直交方向に一定速度 (40 mm/s) で移動するため、ライン撮像レートを 200 Hz にすることにより垂直方向の撮像分解能も 0.2 mm/画素となる。各取得ライン画像をメモリ上で合成することにより、約 5 秒間で 1 024 画素 × 1 024 画素の 2 次元画像が 2 チャンネル同時に得られる。

CH2 の 1 450 nm は水の吸収波長であり⁴⁾ CH1 の 1 200 nm は水の吸収とは無関係な波長であるため、両者の各画素の輝度の比率 (CH2/CH1) の平均値 (平均輝度比) は PKS の水分率と相関がある。この平均輝度比を用いて PKS の水分率を求めるのが計測の基本原則である。

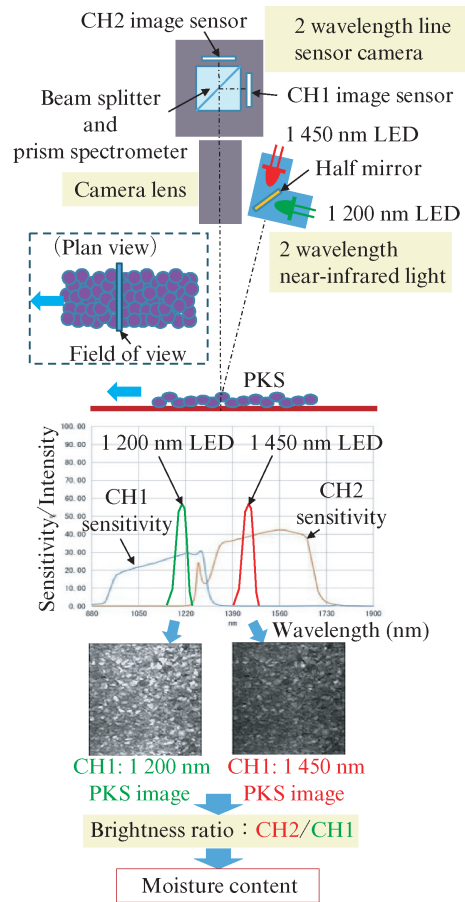


図 1 センサの構成と水分計測原理

Fig. 1 Sensor configuration and moisture measurement principle

2.2 オフライン試験

計測原理を確認するため、ラボ環境で PKS サンプルを用いたオフライン試験を実施した。まず、テネラ種とデュラ種の乾燥 PKS のサンプルを入手し、それに水を加えて所定の水分率の試料を作成した。次に、その試料を入れた容器をリニアステージにセットし、定速で動かしながら画像データを取得し、2 チャンネルの画像から平均輝度比を計算した (図 2)。

図 2 より、水分率と平均輝度比は負の相関があることがわかり、平均輝度比による水分計測原理を確認できる。ただし、以下のような問題があることがわかった。

- 1) 水分率と平均輝度比の関係は、テネラ種とデュラ種で異なる。
- 2) 試料調整時の水分浸透待ち時間や表面乾燥などの管理が難しく、平均輝度比のばらつきが大きい。

1) は、表面付近の近赤外光の散乱特性や水分分布等が PKS 種類によって異なることが理由と考えられる。PKS 種類の目視判別が可能のため、多量の PKS 画像から種類別の特徴を学習し PKS 種類の自動判別を行うことにより、対応

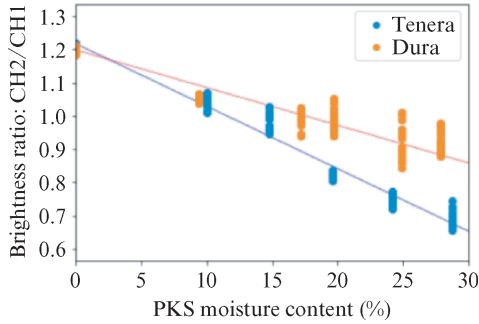


図2 オフラインテスト結果
Fig. 2 Offline test result

が可能と判断した。一方、2) は PKS の水分が均質でないことが原因であり、管理レベルを向上させることで、より均質な状態が望めると判断した。これらにより、オンライン試験に進むことにした。

2.3 オンライン試験

オンライン画像データを収集し、水分計測精度を評価するため、バイオマス発電所の PKS 火炉投入コンベア直前にあるロータリーフィーダ部に図1の構成のセンサ試験設備を仮設した。画像データの収集方法は以下のとおりである。

- 1) 収集期間: 2022年12月~2023年3月
- 2) 10秒ごとに CH1, CH2 のペア画像を取得 (ほぼ同数のテネラ種とデュラ種のペア画像を合計約 80 万ペア)

また、水分率の正解データとして、発電所で6時間ごとに実施している、PKS 水分率の分析結果データを入手・使用した。

2.3.1 PKS 種類判別と水分率推定のモデル

PKS 画像から種類別の特徴を抽出するため、1次元 CNN (Convolutional Neural Network) オートエンコーダを採用した。1次元データを用いたのは PKS 画像が等方的なためであり、CNN を用いたのはデータ圧縮効率が高いためである。1次元 CNN オートエンコーダは、無作為に選んだ1万5千枚の CH1 画像を用い、入力データと出力データの平均二乗誤差が最小になるように学習する。この学習後のエンコーダ部を特徴抽出器として使用する。CH1 画像から1ラインデータを32ラインごとに抽出し、エンコーダ部でそれぞれ256次元のベクトルに圧縮後に平均し CH1 画像の特徴ベクトルとする。

特徴ベクトルには画像特徴が含まれるため、それより PKS 種類の判別モデルを作成した。また、平均輝度比と特徴ベクトルを組み合わせることにより、2種類の PKS に共通な水分率推定モデルを構築した (図3)。これらにより、オンライン試験では PKS 種類を 94% の正解率で判別できた。また、10秒ごとに計算した水分率の1分間平均値の誤差を二乗平均平方根誤差 (Root Mean Squared Error: RMSE) で 1% 以内に収めることができた (図4)。

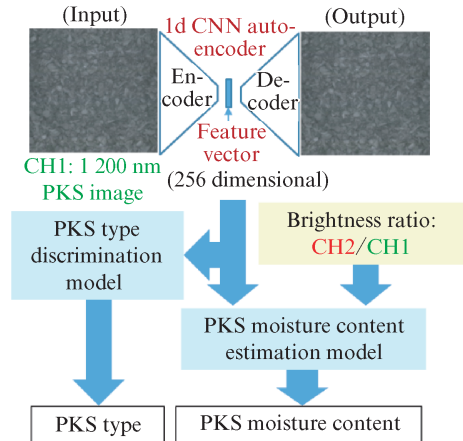


図3 PKS 種類判別モデルと水分率推定モデル

Fig. 3 PKS type discrimination model and moisture content estimation model

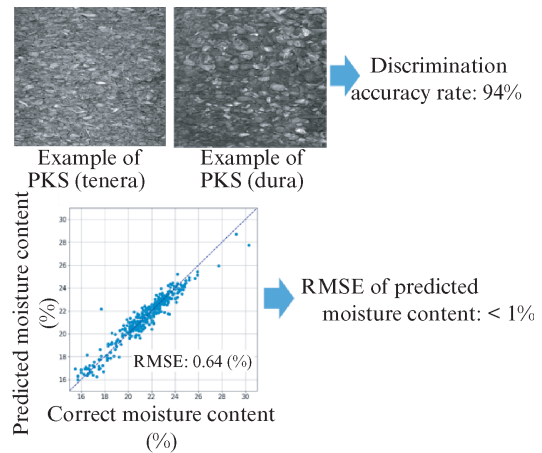


図4 PKS 種類判定精度と水分率推定精度

Fig. 4 PKS type discrimination accuracy and moisture content estimation accuracy

2.3.2 PKS の平均粒度推定方法

PKS の平均粒度推定については、過去に開発した手法⁵⁾をアレンジして適用した。この手法は、画像に含まれる粒子の空間的な輝度変化のパターンを時間信号に見立てたときの周波数 (空間周波数) に着目する。そして、空間周波数のパワースペクトルの拡がり (モーメント) が平均粒度と対応することを利用して指数化する (粒度指数)。視野サイズが同じであれば粒度は画像の倍率に比例し、粒度指数も画像の倍率に比例する (図5)。よって、粒度指数は平均粒度に比例し、基準画像平均粒度から実画像平均粒度を得られる。

CH1 の画像を用いた画像処理方法を図6に示す。原画像の輝度むらを除去した上で2値化して粒子抽出を行う前処理を施すことにより、ノイズの影響を受けにくい安定した推定が可能となった。オンライン試験の結果、粒度指数が PKS 平均粒度と相関係数 0.9 以上の高い相関を示すことを

Spectrum and moment of enlarged image of $f(x, y)$ by 'a' times

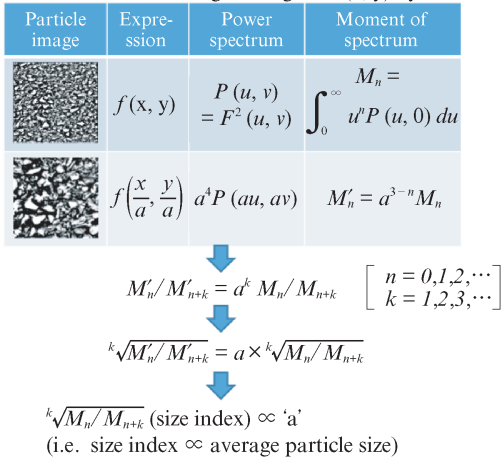


図5 平均粒度推定の原理

Fig. 5 Principle of average particle size estimation

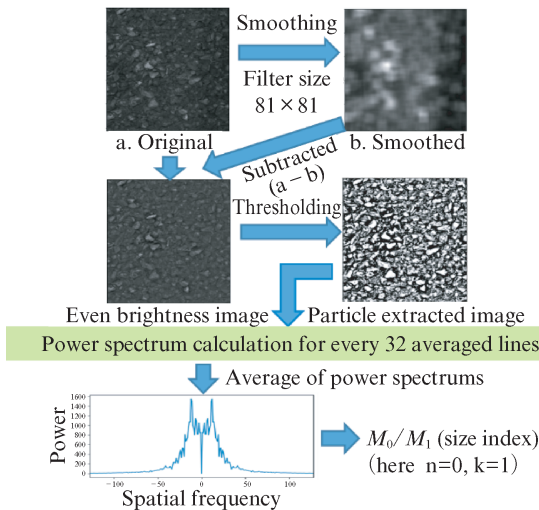


図6 平均粒度推定の画像処理

Fig. 6 Image processing for average particle size estimation

確認した。

今後、燃料性状センサの実用化とバイオマス発電設備の制御高度化へのセンサ情報活用に取り組む予定である。

3. バイオマス発電プラント効率向上に向けた機械学習モデル予測制御系の適用

本章では、機械学習モデルを用いたモデル予測制御を、当社商品である循環流動層（Circulating Fluidized Bed: CFB）ボイラを採用したバイオマス発電設備の送電端効率向上燃焼制御系として適用した内容について報告する。

3.1 CFB ボイラにおける燃料燃焼と送電端効率

CFB ボイラの全体イメージを図7に示す。

バイオマス燃料は供給系統から燃焼室下部に投入され、1




図7 CFB ボイラ発電設備 構成図

Fig. 7 CFB boiler power plant configuration

次空気、2次空気により流動燃焼状態となり、燃焼室出口のサイクロンで流動媒体である珪砂（含灰分）と燃焼ガスとの分離が行われ、珪砂は燃焼室下部に戻る循環燃焼となる。一方の燃焼ガスは熱交換器でボイラ供給水を加熱し蒸気を生成し、熱交換後の燃焼ガスはバグフィルタ経由、煙突より排出される。生成された蒸気によりタービン発電機が制御駆動され安定した電力が生み出される。生成蒸気圧が一定となるように燃料投入量とそれに合った燃焼空気を燃焼室に送り込むボイラマスタ制御が、基本的な制御を司っている。現状では、燃焼状態の安定監視および安全インターロックは行っているものの、燃料種類や含有水分率などの外乱要因も多々ある中での燃焼室内燃焼の複雑さから、燃焼状態制御を直接行い、より良い燃焼状態を作り出すことは考えられてこなかった。

一方で、CFB ボイラ発電設備全体効率、一般的に以下の式（燃料発熱量ベース直接法）により評価されている。

$$\text{送電端効率} = \frac{\text{送電電力}}{\text{燃料単位熱量} \times \text{投入燃料重量}} (\%) \dots (1)$$

そこで、燃料単位熱量は特定銘柄発熱量（一定）とし、送電端効率を直接的な制御指標とする燃焼制御改善方策の検討をスタートさせた。

3.2 機械学習送電端効率予測モデルの構築

制御目標値である送電端効率とボイラ燃焼状態の関係は動的な要素を含めて複雑であり、解析モデルの構築は困難である。この問題に対し、プラント運転データから機械学習で動的予測モデルを作成し、このモデルによるモデル予測制御系（次節）を構築することに取り組んだ。

3.2.1 送電端効率予測モデルにおける特徴量選定

ボイラ火炉内燃焼状態の計測値と操作変数については、現状設備に実装されているものを使用することとし、モデルを構築した。送電端効率予測モデルの入出力状態変数を図8に示す。




図 8 予測モデルの入出力変数

Fig. 8 I/O variables of prediction model

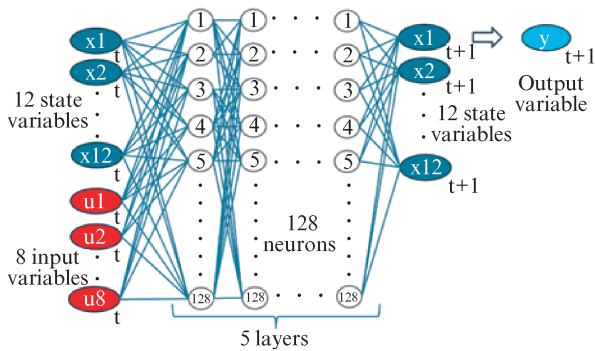


図 9 送電端効率予測ニューラル状態スペースモデル

Fig. 9 Neural state space model for net efficiency prediction

予測モデルの入力および状態変数（特徴量）に関しては、LightGBM (Light Gradient Boosting Machine)⁶⁾ で構成した予測モデルに ALE (Accumulated Local Effect)⁷⁾ による重要度解析を実施し、影響度の高い変数を選定した。また、操作変数には 1 次/2 次空気比とボイラ火焔総差圧を選定した。

3.2.2 送電端効率予測モデルとモデル学習

前項の選定特徴量による予測モデルの構築は、次節のモデル予測制御系 (Model Predictive Control: MPC) が構成可能な Neural State Space (NSS) モデル⁸⁾ によるものとした。NSS モデルは以下のものである (図 9)。

$$x_{k+1} = F(x_k, u_k) \dots\dots\dots (2)$$

$$y_k = G(x_k) \dots\dots\dots (3)$$

ここで、 F : Multi-Layer Perceptron network (MLP), 全結合隠れ層 128 neurons x 5 層, G : [1, 0, ...0]

モデル学習 (1 分サンプリング) は、蓄積プラント運転データの内、最新設備状態 (最終設備改修後) である 2022 年 6 月 8 日~2023 年 12 月 31 日の発電出力 90% 以上の全データを使用した。

3.2.3 学習済予測モデルの精度確認

学習モデルの予測精度確認を、予備試運転時のプロセスデータを用いて実施した。確認には、1 step 先の予測値とともに、後に述べるモデル予測制御系での使い方 ($N_m=10$) に即した形で、10 step 先の予測値について再帰的に予測モ




図 10 学習済予測モデルの精度確認

Fig. 10 Prediction accuracy of predictive model




図 11 モデル予測制御系の構成

Fig. 11 Model predictive control configuration

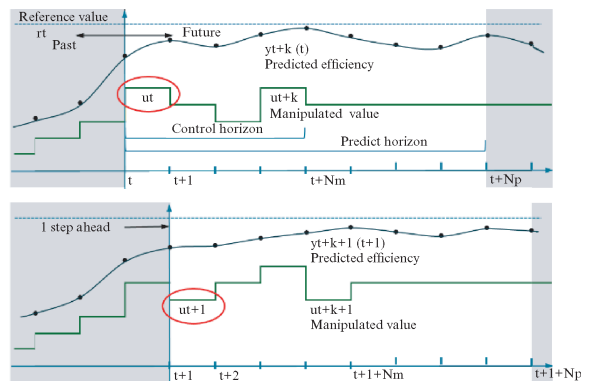


図 12 MPC の予測出力と制御入力の算出

Fig. 12 Predicted efficiency and manipulated value in MPC

デルを使用して算出し、真値と比較した (図 10)。

制御評価区間 $N_m (=10 \text{ step 先まで})$ で二乗誤差平均平方根 RMSE 0.16% 程度の予測精度を得ており、使用に耐える予測精度は確保できると判断した。

3.3 効率予測モデルによるモデル予測制御系構築

前項の予測モデルを用いたモデル予測制御系 (Model Predictive Control: MPC) を構成し、送電端効率を最大化するボイラ燃焼制御系を構築した。

3.3.1 モデル予測制御系 (MPC) の構成

MPC の構成図を 図 11 に示す。MPC の制御対象 Plant に対する操作量 u_t は、サンプリング時刻ごとに予測モデルを参照しながら一定区間 N_p での最適化評価計算を行い、算出された最適操作量の最初の値をその時点の操作量として扱うものとする。具体的な算出イメージを 図 12 に示す。

最適化計算における評価関数は下式 (4) のとおり、一定予測区間 (Predict horizon) N_p に対して、予測モデルから得られる出力予想値 y_t と操作量 u_t により計算される評価値 C_t を最小にする最適操作量 u_t^* を求めるものである。ここでは、区間 N_p の内、制御区間 (Control horizon) N_m では操作量 u_t を変化させ、以降は u_{t+N_m} 一定としている。

$$C_t = \sum_{k=t+1}^{t+N_p} Q(r_k - y_k)^2 \dots\dots\dots (4)$$

実施パラメータは、 $N_m=10$, $N_p=20$, $Q=4$,

また、上記、最適化計算の中では、最適化条件として、操作量 u_t およびその変化量 $\Delta u_t = u_t - u_{t-1}$ に対して、それぞれ上下限範囲設定が可能である。今回のように、運転領域における安全状態確保が必要である制御対象について、まったく考え方が異なる制御機能を追加するケースでは、有効かつ必要な機能となっている。

3.3.2 既存燃焼制御装置機能の取り込み

1章で触れた既存バイオマス発電設備負荷低減データベース制御⁹⁾では、総空気を燃焼必要量まで絞ることにより押込・誘引通風機の所要電力を減らす、送電端効率向上に直接寄与する制御を行っている。そのため、本 MPC の操作量である 1 次/2 次空気比制御 (実際には総空気を維持したまま 1 次空気量の増減により比率を制御) と相互干渉する可能性がある。この干渉を避けると同時に、既存制御が持つ、所要電力軽減機能とボイラ炉内燃焼監視機能 (炉内温度分布の監視) を利用するため、既存燃焼制御装置機能を取り込むこととした。MPC の 1 次空気量制御 (1 次/2 次空気比制御) に対しては、既存制御から得られる 1 次空気量下限値制限を生かすことで、共存・合体をはかった。

3.4 MPC の実装と試験状況について

前項で構成した MPC を社内 CFB ボイラに適用し、試験運転を行い、効果を確認した。

3.4.1 MPC の試験実装

MPC 試験実装は、当社 Global Remote Center: GRC エリアの Amazon Web Service: AWS の EC2 インスタンスの MATLAB®/Simulink®^{*1} でを行い、現場制御装置 (DCS) とは OPC UA による接続とし、プロセス I/O を得た (図 13)。




図 13 MPC 実装概念図

Fig. 13 Conceptual configuration of MPC system

3.4.2 現状試験の状況・結果と考察・今後の対策

試験運転は、すべて立ち会い運転監視のもと、各日 9:00~17:00 の通常操業に対して MPC を連続適用して行った。MPC 適用効果の確認は、前述の送電端効率評価式 (式 1) により、各日試験全時間における平均送電端効率と、試験前後日の MPC 非適用時の同様数値とを比較することで行った。投入燃種については前後数日を含めて受入バッチを合わせるものとした、一方で、操業自体の条件設定は行わず、平時操業状態とした。

以上の方法による現在までの試験結果では、残念ながら、安定的な効率向上は確認できていない。この結果はある程度予想されたことでもあり、以下に考察および今後の方針を記述する。

(1) 効率予測モデルについて

試験期間のプロセス入出力結果に基づき、予測精度を 3.2.3 項で述べた方法により確認したところ、ほぼ同等 (10 step 先において RMSE 0.22%) の予測精度が確保されていることを確認した。

これにより、選定した特徴量によるモデル構築自体は妥当と判断した。

(2) 送電端効率評価式について

ボイラの効率向上制御における効率計算値の精度および再現性の確保が難しいことは、従来より問題点として挙げられている¹⁰⁾。今回使用した送電端効率評価式 (式 1) についても、燃料条件を整えた状態 (例えば性能評価試験) の用途向けであり、実操業下では燃料種類や水分含有率を含む燃料性状が大きく燃焼状態に影響を与えていることは予想されていた。本問題に対応するため、2章で報告した燃料性状オンライン計測値 (燃料種類, 含有水分率) に基づく、より精密な制御用送電端効率式を新たに定義・使用する、新しい予測モデルの構築を計画している。

4. まとめと今後の展望

AI・ビッグデータ活用によるプラントエンジニアリング計測および制御分野における至近の技術開発事例について報告した。現時点までの結果として、PKS 燃料性状 (水分率, 種類, 粒度) 計測については、実用レベルの原理的検証結果を得ることができた。一方、燃焼効率向上制御系の構成については、手法適用の可能性を見出したレベルにとどまっている。どちらも開発途中であるものの、従来は困難であった技術課題に対して、ある種汎用的な解決手段 (ワークフロー, 基盤技術) を確立することを基本目標としている。まずは本報告での課題を解決して、技術検証を確かなものにしていきたいと考えている。

参考文献

- 1) 日本学術会議 情報学委員会 E-サイエンス中心科学分科会. AI・ビッグデータ利活用 発展動向調査統合版. 2017年6月
 - 2) 水上潔 他. 計測と制御 特集 スマート・マニュファクチャリング. 2024, vol. 63, no. 12, p. 729-774.
 - 3) 妹尾光敏, 小林義孝. JFE エンジニアリングにおける AI・ビッグデータの活用. JFE 技報. 2020, no. 45, p. 59-64.
 - 4) 尾崎幸洋. 近赤外分光法. 1版, 講談社, 2015, 286p.
 - 5) Harayama, M.; Uesugi, M. On-line Measurement of Average Pellet Size with Spatial Frequency Analysis. In Proc. IECON92.1992.
 - 6) Ke, G.; Meng, Q.; Finley, T. et al. LightGBM: A Highly Efficient Gradient Boosting Decision Tree. In Proc. 31st Conference on Neural Information Processing Systems (NIPS 2017). 2017.
 - 7) Apley, D.W.; Zhu, J. Visualizing the Effects of Predictor Variables in Black Box Supervised Learning Models. In Journal of the Royal Statistical Society Series B: Statistical Methodology. 2020, vol. 82, no. 4, p. 1059-1086.
 - 8) Forgione, M.; Mejari, M.; Piga, D. Learning Neural State-space Models: Do we need a state estimator?. arXiv:2206.12928v1. 26 Jun 2022.
 - 9) 中尾展行, 島本拓幸, 山本晃司. 多種燃料対応 CFB 燃焼制御システム. JFE 技報. 2010, no. 25, p. 11-16.
 - 10) 栗原伸夫, 中野善之, 福島弘一朗. 火力プラントにおけるボイラの高効率化制御. 日立評論. 1981, vol. 63, no. 2, p. 35-40.
- *1 MATLAB®, Simulink®およびその他の製品は, The MathWorks, Inc. の登録商標または商標です。