

デジタルツインとデータ駆動型最適化： 持続可能なインフラ運用の未来



特集
ハイテク推進
セミナー

株式会社シグマクシス ディレクター／大阪大学 特任研究員
馬 越 龍太郎 氏

1. はじめに

近年、インフラストラクチャ分野におけるデータ駆動型制御技術の進展は目覚ましく、次世代の発電所および製造プラントにおいてデジタルツイン制御への移行が進んでいます。この動向は、インフラ運用の効率性と柔軟性向上への期待に加え、リアルタイム最適化がもたらす新たな制御パラダイムの創出によってさらに加速されています。デジタルツイン制御技術は、人間と機械が協働し、リアルタイムで生産品質を監視しながら、多様な運用制約のもとで効率と生産性を最大化する高度なデータ駆動型制御手法です。

従来のモデル予測制御 (MPC) は、多目的・多変数の最適化問題に対処する際、計算負荷が高く、リアルタイム制御の実現が難しいという課題に直面してきました。特に、非線形システムへの適用では計算負荷が増加し、オンラインでのフィードバック制御には適さない場合があります。しかし、近年の機械学習および数理最適化アルゴリズムとそのアーキテクチャの飛躍的な進展により、これらの課題は解決に向かっており、複雑な非線形確率過程に対する

動的な制御方策の学習が可能になりつつあります。本稿では、デジタルツイン制御の簡易な実例を紹介し、そのアプローチ方法を解説します。

2. デジタルツイン制御の概要とその必要性

デジタルツイン制御は、観測されたセンサーデータと工学的に生成されたソフトセンサーを基に、機械学習を活用してモデルを構築し、インフラシステムのパフォーマンスをリアルタイムで監視・予測・最適化する技術です。インフラ運用においては、複数の KPI (重要業績評価指標) を同時に最適化する必要がある一方で、相反する目標や複雑な制約条件に対処しつつシステムの最適化を図ることが求められます。

従来のプロセス自動化制御システムは、状態空間データに基づく即時応答的なアクティブアプローチでしたが、デジタルツイン制御は、長期的な計画に基づき、相反する目的を調整するプロアクティブで戦略的な制御アプローチを可能にします。図 1 にデジタルツイン制御の高度化ステップを示しています。制御は単入力单出力 (SISO) から多入力多出力 (MIMO) へと進化し、予測モデルを用いた最適化制御 (MPC) が一般的なアプローチとなっています。

MPC は、予測ホライズンと呼ばれる有限の時間区間で最適制御問題を繰り返し解き、得られた制御入力の最初の要素のみを適用することでフィードバック制御を実現します。しかし、このアプローチにはオンライン計算の負荷が大きく、特に大規模な確率的 MIMO 問題においてリアルタイムでの実用化が難しいという課題があります。

さらに、不確実性のあるシステムに対して従来のアプローチでは、限られた不確実性シナリオ（たとえば、特定の環境条件や物理システムのパラメータ範囲内に限定したケース）を仮定するため、実際の予測困難で複雑な環境変動には十分に対応しきれな



講師 馬越 龍太郎 氏

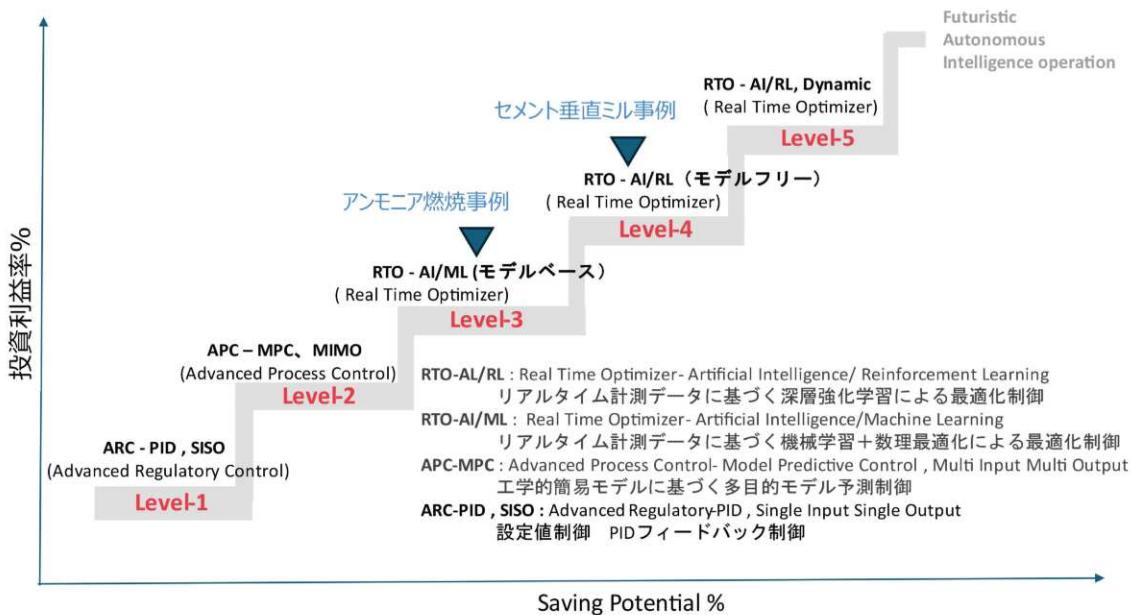


図1 デジタルツイン制御の高度化ステップ

いという課題も存在します¹⁾。

MPC の限界を克服するため、実データに基づくモデルを活用してリアルタイム最適化を実現する RTO-AI/ML (リアルタイム最適化 - 人工知能 / 機械学習) 手法が導入されています。このアプローチでは機械学習による回帰モデルが使用されますが、モデルの維持にはチューニング等のメンテナンスに高コストがかかり、動的システムの変化に迅速に対応するのが難しい場合があります。

そこで、更なる高度化のステップとして、デジタルツイン制御のモデルフリーのアプローチである RTO-AI/RL (リアルタイム最適化 - 人工知能 / 強化学習) では、深層強化学習 (DRL) を活用^{2)~4)}し、最適化のための戦略的な制御方策を学習することで、モデル同定が困難なプロセスにも適用可能になります。DRL は環境と相互作用しながら最適な行動方策を学習し、連続的かつ非線形な確率過程を含む複雑な最適化問題に対して柔軟かつ適応的に対応します。

また、いずれのデジタルツイン制御の構築においても、モデリングや最適化手法に加え、データ特徴量抽出や変数選択のデータマイニングが重要な要素であり、運用のニーズに合わせたアーキテクチャ設計が必要になります。

3. モデルベースおよびモデルフリーのデジタルツイン制御の構築

3.1 モデルベースのデジタルツイン制御

モデルベースの RTO-AI/ML について、大阪大学のアンモニア燃焼実証炉⁵⁾における最適化運転事例を紹介し、デジタルツイン制御の構築手法を解説します。工業炉におけるアンモニア燃焼では二酸化炭素の排出はないが、環境変化および工業炉の目的に応じた様々な制約条件で、排気中の未燃アンモニアの抑制と有害な窒素酸化物 (NO_x) の低減を安定的に維持することが、実炉運用における重要な課題となっています。そこで、図 2 に示す 100kW アンモニア燃焼実証炉を用いて、運転最適化の課題を設定し、複数の相反する目的変数を同時に最適化する制御アルゴリズムの構築プロセスが有効であることを実証しました。本実証では、炉内の特定の空間温度を均一に保持しながら、未燃アンモニアの排出を抑制し、炉加熱効率を最大化しつつ、 NO_x の排出を最小化することを目標に課題を設定しています。操作変数は、アンモニアと酸化剤（空気）それぞれの 2 系統の供給量です。炉加熱効率は、炉内温度を適切に維持するために必要なアンモニア消費量の指標（被加熱体による拔熱がない加熱効率）として定義されました。

この構築プロセスでは、まず、計測された時系列データから統計的に準定常データを抽出し、統計量

最適化課題の設定

炉内目標空間温度を均一化、排気未燃アンモニアを抑制し、炉加熱効率最大化、 NO_x 最小化する制御

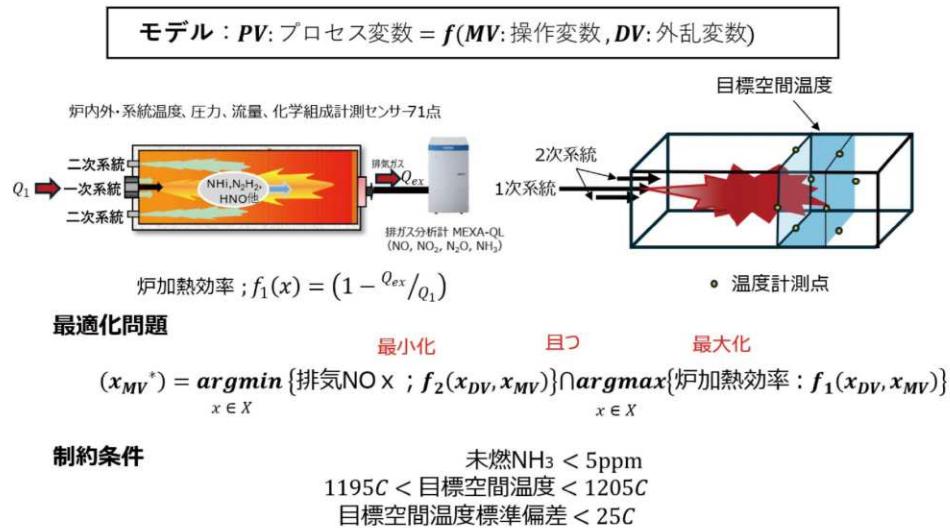


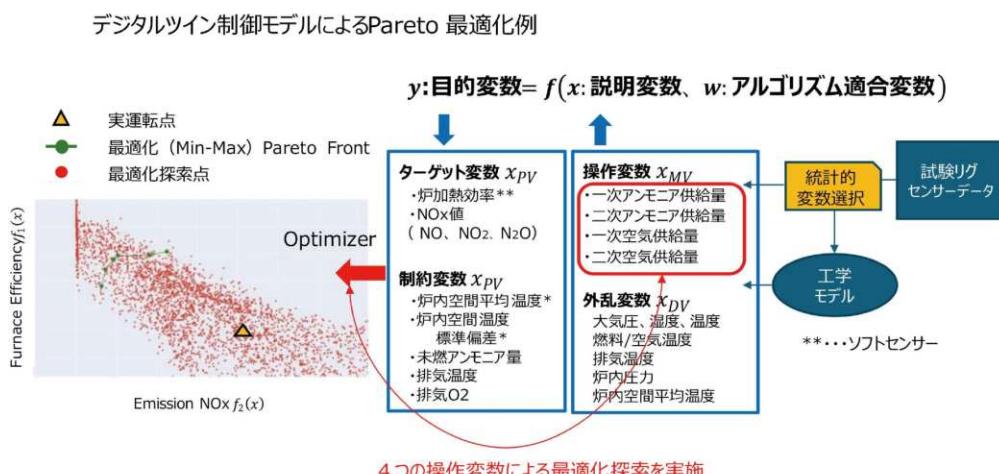
図2 100kW アンモニア燃焼炉のデジタルツイン制御の開発

や機械学習により変数の重要度を評価しました。これにより、9つの目的変数に対し、4つの操作変数（アンモニアと空気それぞれの一次および二次の供給量）と外乱変数（炉内圧力、大気温度、大気湿度、大気圧、供給燃料温度など）を含む11個の説明変数が選定されました。モデル選定においては、20種類の機械学習アルゴリズムからPLS、SVR、Kernel Ridge、MLPが精度と感度の指標から選定され、さらにハイパーパラメータの適切な探索を行うことで、最適な予測モデルが構築されました。

本手法の特徴は、予測精度だけでなく、工学的な

表現力を重視した点です。具体的には、操作変数に対する目的変数のモデルの感度（操作変数に対する機械システムの反応方向性）を Spearman 相関係数で指標化しました。この感度指標をモデル選定基準に組み込むことで、少量の訓練データでも予測精度と感度のバランスを保つことが可能となり、最適化の信頼度が確保されます。データ収集では、実験計画法による学習データを効率的に収集し、並行して操作変数に対する感度を確認する適切な試験を実施しました。

図3にはモデルベース最適化の結果を示していま



*...被加熱体品質を炉内特定域の温度の平均と分散として模擬

図3 100kW アンモニア燃焼炉の最適運転の予測結果 (RTO-AI/ML.)

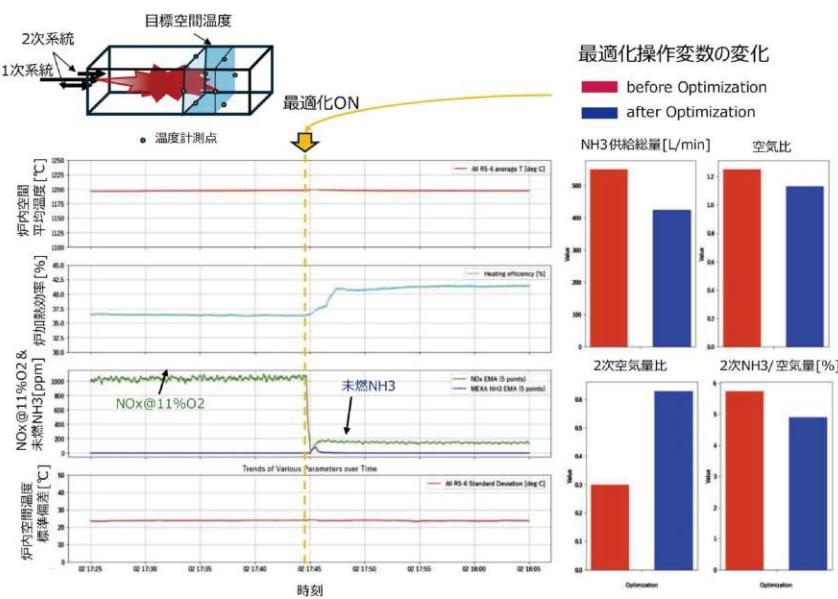


図4 100kW アンモニア燃焼炉の最適運転の実証結果 (RTO-AI/ML.)

す。ここでは、PSO (Particle Swarm Optimization) を用いて最適な操作変数を探索し、炉空間温度の平均値と均一性、および未燃アンモニア量の抑制を制約条件として、炉加熱効率の最大化と排気 NO_x の最小化を目指した最適化解がパレートフロントとしてプロットされています。また、図4には、この最適化解に基づく操作変数を用いて実証炉を最適運転した際のトレンドを示しています。目標通り、炉加熱効率の最大化と排気 NO_x の最小化をリアルタイムで実現していることが確認できます。

このデータ駆動型アルゴリズムの構築プロセスは、

被加熱物を扱う様々な燃焼器や実工業炉への適用が可能であり、幅広い産業分野における制御最適化への応用が期待されます。

3.2 モデルフリーのデジタルツイン制御

デジタルツインのモデルフリー制御アプローチである RTO-AI/RL は、深層強化学習 (DRL) を活用して、試行錯誤を通じて長期的な報酬を最大化するための最適な制御方策を学習します。制御方策は最適行動（最適操作値）の確率分布で与えられます。DRL は、環境と相互作用しながら最適な行動方策

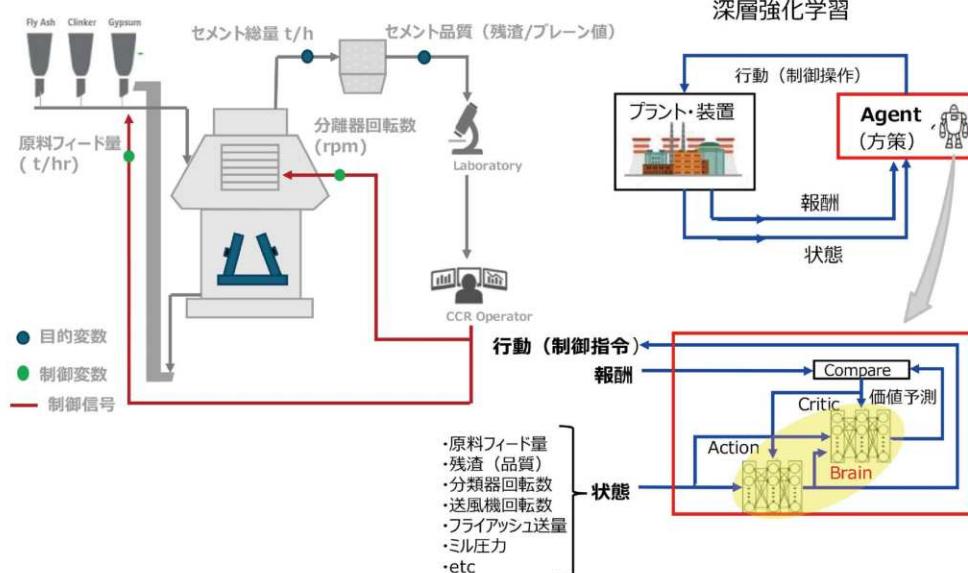


図5 セメント垂直ミル最適化スキーム (RTO-AI/RL)

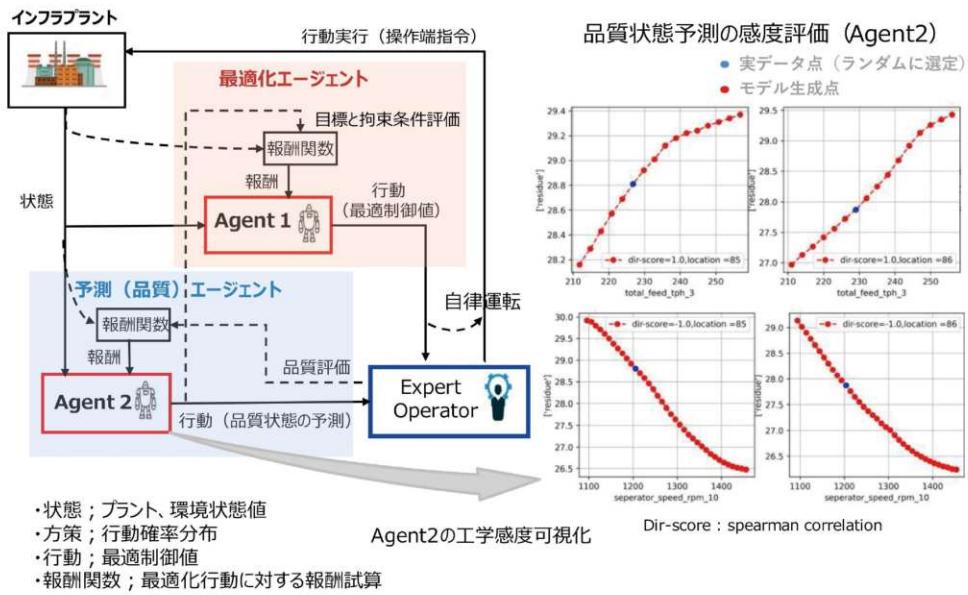


図6 セメント垂直ミルのデジタルツイン制御アーキテクチャ (RTO-AI/RL)

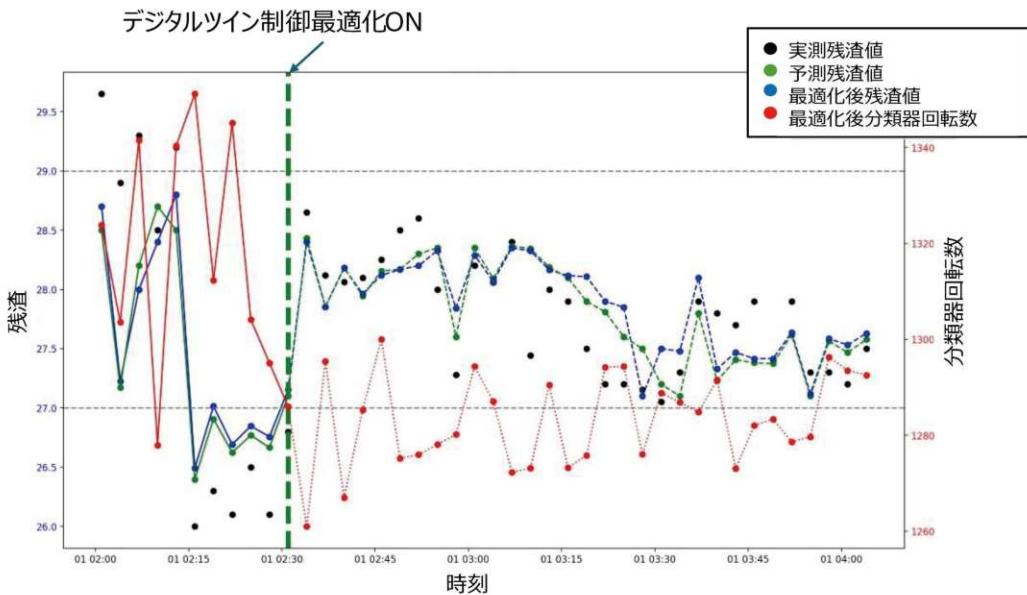


図7 セメント垂直ミル最適運転の実証結果 (RTO-AI/RL)

を獲得することで、複雑な非線形連続プロセスの最適化に有効であり、リアルタイムでの学習と予測が可能です。DRLのエージェントは制御を担う学習主体であり、目的が達成されると、設定された報酬関数に基づいて報酬がエージェントに与えられ、行動方策が強化されます。エージェントは常に行動の価値を予測し、最適な行動（制御操作）を選択します。現実空間で報酬が得られない場合には、深層学習を通じて再学習を行い、行動方策を最適な方向へと修正します。最適化は、任意の状態から累積報酬が最

大になるように、エージェントが最適な方策に基づいて制御を実行します。

図5に示されるセメント製造の垂直ミル運転への適用事例では、深層強化学習アルゴリズムの一つであるPPO (Proximal Policy Optimization)⁶⁾が使用され、Actor-CriticアーキテクチャにはCNN (Convolutional Neural Network) が選択されています。PPOは、方策の更新時に大きな変動を抑える制約を設けることで、安定した学習と効果的な多目的最適化を実現しています。

図6のアーキテクチャは、品質予測を担当するエージェント2（ソフトセンサー）と、その予測結果に基づいて最適化を行うエージェント1による階層構造で構成されています。エージェント2はプラントの状態データを活用して、セメント製品の品質（残渣：residue）を予測するように訓練されています。一方、エージェント1はエージェント2の予測を基に、品質目標を維持しながら、総フィード量の最大化と電力消費（分類器回転数）の最小化を同時に実現する最適な制御値を出力するように設計されています。

このDRLアーキテクチャでは、人間から提供される品質評価や品質要求といった断続的なフィードバック（Human Feedback）を活用し、再学習を行います。さらに、エージェント2が生成した予測データをエージェント1に送信することで、原料の性状変化やミルローラの劣化など、プラント環境の変動に柔軟に適応し、最適な運転を実現します。

図7に、このDRLアーキテクチャを用いた最適化結果のトレンドを示します。目標通り、セメントの品質のばらつきが抑制されるとともに、分類器回転数の低減が確認され、実用化されています。

また、このアーキテクチャではリアルタイムで予測パフォーマンスの応答感度を評価できます。図6に示す感度図からは、セメント垂直ミルの運転点における分類器回転数の変化に伴う品質（残渣）の傾向を把握することができ、回転数の増加により残渣が減少する（粒度が細くなる）予測が確認されます。このように、操作変数に対する反応方向を感度評価できるアーキテクチャの構成は、オペレーターがアルゴリズムの信頼性を評価する上で重要です。

4. 結語

最新のアルゴリズム技術は、生成AIやデジタルツイン制御技術の急速な進化に伴い、新たな段階に入っています。欧州が提唱する「インダストリー5.0」において、人間と機械の協働による持続可能な社会の実現に向けた取り組みが進み、クロスネットワークの全体最適化と人間中心のアプローチがますます重要視されています⁷⁾。

生成AIの一般言語モデルは、Transformerの自己注意（Self-Attention）メカニズムにより予測精度を飛躍的に向上させています⁸⁾。一方、デジタル

ツイン制御に特化したAIアーキテクチャでは、工学的な表現力として感度（Sensitivity）を組み込むことで、最適化の信頼性が向上し、複数の目標を同時に最適化する革新的なソリューションの提供が可能になります。

また、デジタルツイン制御技術が物理シミュレーションとハイブリッド統合することで、多様な工学分野において高精度な予測と最適化が可能となり、今後の技術革新において重要な役割を果たすことが期待されます。さらに、生成AIとデジタルツイン制御が連携することで、コード化された構築プロセスを通じてアルゴリズムの自動生成が加速することも見込まれています。これらの技術の進展により、複雑なクロスネットワークから成る社会インフラに対して、運転条件や環境に応じた最適な制御ロジックがリアルタイムで効率的に適応され、Human Feedbackアーキテクチャを通じて人間の意思や情報が最適化に反映されることで、人間と機械の柔軟で効率的な協調運転が可能となります。この技術革新は、資源の効率的な利用や産業におけるカーボンニュートラルの達成を促進し、持続可能な社会の実現に向けて重要な役割を果たすと期待されています。

謝辞

大阪大学のアンモニア燃焼実証試験のデジタルツイン制御の実証の成果は、NEDO（国立研究開発法人新エネルギー・産業技術総合開発機構）の委託業務（JPNP23016）の結果得られたものです。

参考文献

1. L. Hewing, K. P. Wabersich, M. Menner, and M. N. Zeilinger, "Learning-based model predictive control: Toward safe learning in control," *Annu. Rev. Control, Robot, Auton. Syst.*, vol. 3, pp. 269–296, May 2020.
2. R. Nian, J. Liu, and B. Huang, "A Review on Reinforcement Learning: Introduction and Applications in Industrial Process Control," *Computers & Chemical Engineering*, April 9, 2020.
3. J. Biswas, A. Goyal, B. Selvanathan, and V. Runkana, "Application of Reinforcement Learning for Real-Time Optimal Control of the

- Pellet Induration Process," Transactions of the Indian Institute of Metals, May 2022.
4. O. Dogru, J. Xie, O. Prakash, R. Chiplunkar, J. Soesanto, H. Chen, K. Velswamy, F. Ibrahim, and B. Huang, "Reinforcement Learning in Process Industries: Review and Perspective," IEEE/CAA Journal of Automatica Sinica, vol. 11, no. 2, February 2024.
 5. Y. Yang, T. Hori, S. Sawada, and F. Akamatsu, "Numerical investigation on the effects of air-staged strategy and ammonia co-firing ratios on NO emission characteristics using the Conjugate heat transfer method," The Science and Technology of Fuel and Energy, July 15, 2024.
 6. J. Schulman, F. Wolski, P. Dhariwal,
 - A. Radford, and O. Klimov, "Proximal Policy Optimization Algorithms," arXiv:1707.06347, 2017.
 7. Tim van Erp, Nubia Gabriela Pereira Carvalho, Mateus Cecilio Gerolamo, Rui Gonçalves, Niels Gorm Malý Rytter, Bartłomiej Gladysz, "Industry 5.0: A new strategy framework for sustainability management and beyond," Journal of Cleaner Production, 2024.
 8. A. Vaswani, N. Shazeer, N. Parmar, J. Uszkoreit, L. Jones, A. N. Gomez, L. Kaiser, and I. Polosukhin, "Attention Is All You Need," 31st Conference on Neural Information Processing Systems (NIPS 2017), Long Beach, CA, USA.

