

# 石油精製、石油化学分野での AI 活用

## Application of AI to Oil Refineries and Petrochemical Plants

大谷 哲也<sup>\*1</sup>  
Tetsuya Ohtani

人工知能（AI）、機械学習、データサイエンスなどの技術が近年著しく進歩して、従来は人手で行うことで時間が掛かっていた作業を、コンピュータが代わりに処理できるようになってきた。製造業においても、技術の進歩に伴って大量のデータを扱えるようになったため、大量のデータからAIが自動的に課題を発見して、解決策を提示することが望まれている。本稿では、石油精製、石油化学分野における、設備と品質に関する課題に焦点を当てて、AIを活用して課題を解決する方法と事例を紹介する。

Artificial intelligent (AI), machine learning, data science, and other advanced technologies have been progressing remarkably, enabling computers to handle labor- and time-consuming tasks that used to be done manually. As big data have become available, it is expected that AI will automatically identify and solve problems in the manufacturing industry. This paper describes how AI can be used in oil refineries and petrochemical plants to solve issues regarding assets and quality.

### 1. はじめに

資源・エネルギー開発、地球温暖化対策、災害予知・予防、育児・介護支援、難病疾患治療など、持続可能な世界の実現に向けた様々な取り組みにおいて、先端科学技術の開発が欠かせない。製造業においては、安全第一と安定生産を前提として、高付加価値製品の開発と、効率の良い生産が望まれている。それらを実現するためには、多くの知識と知恵の融合が必要であり、そのために、人工知能（AI）、機械学習、データサイエンスなどの技術が活用されており、これらの技術をベースにした図1のようなプラットフォームが活用されている。

本稿では、石油精製、石油化学分野の製造における課題を整理した上で、それぞれの課題に対するAI活用について、事例を交えて紹介する<sup>(1)(2)</sup>。最後に、今後の展望について述べる。

### 2. 石油精製、石油化学分野における課題と要求

石油精製、石油化学分野における最大の課題は、生産設備を維持して生産を継続することであり、設備の故障や人為的ミスなどによりシャットダウンを余儀なくされた場合、その損失が非常に大きい。そのため、設備故障の予知に対する期待は大きい。生産設備を安定して稼働させることができると、次は生産性向上と利益最大化が望まれる。石油精製、石油

化学分野においては、分離精製にかかるエネルギー消費が大きいため、その消費量を最小にすることも重要である。



図1 AI、機械学習、データサイエンス  
プラットフォーム

ここでは、課題を設備課題と品質課題に分けて紹介する。設備課題では、設備の故障予知に加えて、故障や劣化を促進する原因を探ることが求められる。一方、品質課題では、品質をリアルタイムで可視化することに加えて、品質そのものの劣化の原因についても探ることが求められる。

次章以降で、これらの課題とその解決方法を順に紹介する。

### 3. 設備の予防保全

石油精製、石油化学分野における生産設備は、定期修理などにより計画的にメンテナンスされている。しかし

\*1 デジタルエンタープライズ事業本部  
デジタルエンタープライズソリューションセンター

ながら、特にコンプレッサやポンプなどの回転機器は、原料の違いや環境変化の影響を受けて部品の摩耗や劣化が予想以上に進み、通常より早く性能の低下や故障につながることがある。予期しないプラント停止に追い込まれると被害が大きいため、故障を予知して、事前に対策を打つことが重要である。少しでも早くメンテナンス計画を新たに、または追加して立案・実施することにより、生産ロスを最小限に抑えることができる。

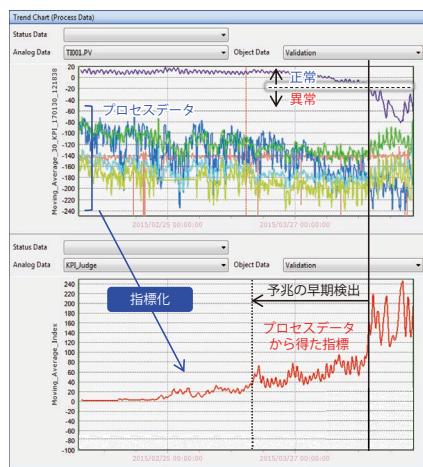


図2 プロセス変数と異常予測

ここでは、従来の振動計や電流計などによる直接的な異常検知だけでなく、プロセス状態から設備の性能劣化や異常を早期に検知することを目指す。そのために、機械学習を用いて、所望の性能が発揮されている状態に比べて、プロセス変数間の関係性が変わってきたことを検知して、早期に異変を発見する。図2の上段の図はプロセス値の時間変化を示しており、右端においてプロセス値が異常を示している。一方、下段の図は異常の早期検出を目的として、複数のプロセスデータを入力として作成した機械学習モデルの出力値である。上段の図で示したプロセスデータによる異常検知より早く機械学習モデルの出力値が上昇しており、異常の予兆を検出できている。

異常には、様々なケースがあり、過去のプロセス変数の関係から、必ずしも将来の異常予兆を検知できるとは限らない。そのため、各プロセス変数の動きがいつもと違う場合にアラームを発生して、後は人の判断に任せせる方法も併用する。

図3は温度の時系列データにいつもと違う動きがあつた場合にアラームを出す例である。図3の上段の図では、温度の時系列データに大きな動きがあつた部分の波形を自動的に検出して、いつもと違った動き（異常）があつた部分に印をついている。図3の中段は抽出された異常波形、下段は大きな動きがあつたが正常であった波形の例である。これは、過去の時系列データの中から見つけた結果であるが、リアルタイムに適用するといつもとの違いを知らせるアラームを実現できる。

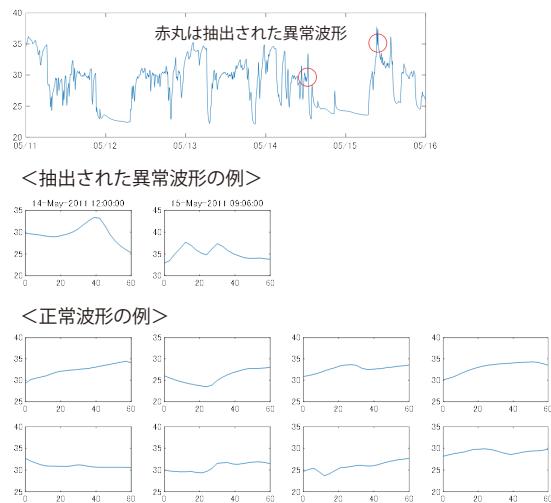


図3 温度時系列データと抽出した波形

#### 4. 設備劣化および異常の要因解析

設備異常の予兆を検出するだけではなく、今後のためにはその発生原因を調べて改善したい、という要求がある。コンプレッサの汚れによる性能劣化、タンクの腐食による漏れ、錆の混入、重合などによる装置の詰まりなどは、早期に検出するだけでなく、検出と同時に、その発生原因の特定が求められる。発生原因を特定するためには、異常が起きた時とそうでない時、また、設備劣化が起きた時とそうでない時を比較して、何が違っているかを分析することが求められる。原因を特定するためには、原因に関する仮説を立てて、データを用いて順にその仮説を検証することになる。

異常状態のデータをある程度の量で収集できている場合には、正常か異常かを判定する識別器を機械学習により作成する。そして、得られた識別器のモデルを分析することで、どのプロセス変数が、正常と異常を分ける因子として貢献度（影響度合い）が高いかを調べることができる（図4の解決法1）。

しかしながら、一般に異常状態のデータは少ないので、データが十分にある場合に使用可能な正常状態と異常状態を比べる手法や識別器を作る手法が使えない場合も多い。その場合は、運転状態をクラスタリングと呼ばれる手法によりいくつかのグループに分け、異常が起きた運転状態を含むグループを詳しく調べる方法がある。そのグループの特徴から異常が発生する可能性が高い条件を導く（図4の解決法2）。

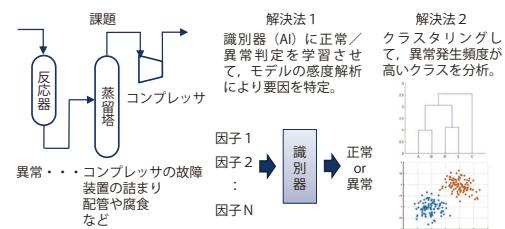


図4 設備劣化および異常の要因解析

また、正常データの特徴を学習して、その特徴から離れた場合に異常と判断する機械学習の手法がある。この手法を用いて異常と判断すると、その判断への貢献度が高いプロセス変数が、その貢献度順に分かるようになっている。図5の下段中央のグラフが異常度合いを示しており、徐々に上昇していることがわかる。この時、下段右のグラフが異常度上昇の原因となったプロセス変数の貢献度を示している。

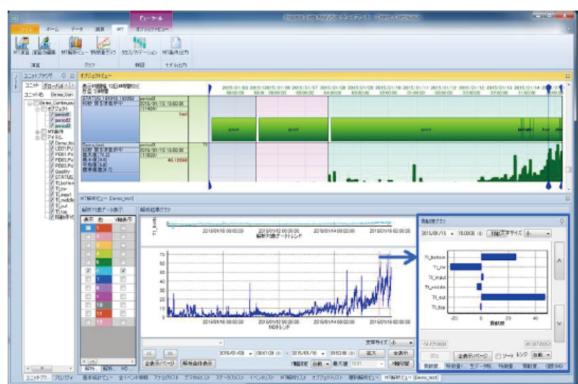


図5 設備異常検知と要因ランキング

特に、配管に腐食や詰まりなどの異常が起きると蒸留塔の分離性能が落ちるなど、生産に支障をきたす。差圧の増加などにより異常が発生している状況を観測することはできるが、その原因を見つけるためには、上述の方法が用いられる。各プロセスでは、正常運転を維持するために多くの管理ポイントが設けられているが、通常、そのポイントにおけるプロセス変数の重要度合いが十分には把握できておらず、解析した結果、予期せぬ原因が見つかることも多い。

## 5. 品質予測モデルの構築

製品品質を測定するためには、結果を得るまでに時間がかかるラボ分析などを行うため、リアルタイムに製品品質を知ることができない場合が多い。例えば、原料や環境条件などの違いにより、製品品質が変わることがあるが、分析結果が得られるまでには時間がかかる。よって、リアルタイムに測定可能なプロセスデータから製品品質をリアルタイムに予測するモデルの構築が求められる。この予測モデルは、複数のプロセス変数を入力として、製品品質の予測値を出力するものであり、過去の実績データを用いて、線形回帰モデルあるいは非線形の機械学習モデルが作られる。

このような予測モデルの問題は、過去の実績データから作成したモデルを将来予測に用いるが、プロセスの状態がモデルを学習したときの状態とは変わっていて、予測値がずれてくることである。例えば、反応プロセスにおける触媒の劣化や、原料組成の変化、その他の外乱により、予測モデルにオフセットが生じる。

徐々に予測値がずれていくことに対応して、適応型の

モデルが数多く提案されているが、主に次の二つの手法が有効である。一つは、時間的に予測値がずれていくという仮定に基づいて、最近の予測誤差を参考に予測値を修正する方法である。もう一つは、運転条件が近い場合は、モデルの誤差が同じように再現されるという仮定に基づいて、過去の実績データの中から運転条件が近いデータを集めて、これらの予測誤差を参考に予測値を修正する方法である。これらの手法を合わせて、Just In Time (JIT) モデル<sup>(3)</sup>と呼んでいる。多くの場合、これらの修正により予測精度が改善される。

図6は、JIT モデルによる修正を加えた結果である。青線が JIT モデル適用前、赤線が JIT モデル適用後の結果である。この時、縦軸が予測誤差であり、2本の横線の間が望ましい予測正解範囲とすると、JIT モデルによりずれが修正されて、正解率が 46% から 51% に改善している。

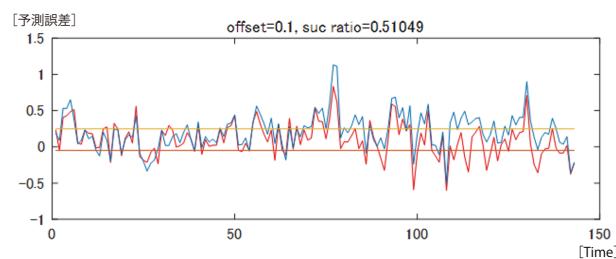


図6 JIT モデルによる予測精度の向上

ある触媒反応プロセスにおいては、反応量を一定にするため、触媒劣化に伴い反応器の温度を上昇させる必要がある。この場合、反応器の温度が上昇しても、反応量は変わらず一定である。よって、温度の変化に合わせて反応状態を予測しても、触媒が劣化していく影響を考慮しないと、予測値が徐々にずれていく。このような時に、Just In Time モデルによる適応型予測モデルが有効になる。

## 6. 品質異常の要因解析

品質の問題は、石油化学製品、バッチ生産において特に重要になる。製品品質と生産量の間にトレードオフ関係があり、両方を同時に高めることが難しい場合もある。そこで、生産量を抑えて製品品質の向上を図ったとしても、原料や環境条件の変動など、何らかの原因により製品品質にバラツキが発生して、ある割合で不良品が発生することがある。製品品質の不良発生には様々な原因があり、簡単には原因を特定できないので、不良発生に関して要因を解析するニーズは高い。

要因解析には、一般に二つの方法を併用する。一つは、製品品質とプロセス変数との相関を一つ一つ見ていく方法である。各工程での製造条件を示すプロセス変数と製品品質の測定値との関係を、散布図にプロットして関係性を見出していく（図7の解決法1）。しかし、散布図を

描いても相関が見えないことが多い、他の条件、例えば、製品銘柄や生産量、季節など他の条件の違いにより色分けすると、相関が見えてくることが多い。これを層別分析といい、相関解析の常套手段である。図7の下段の図は、特殊な運転モードのデータを除いた結果（層別）、良品／不良品と説明変数との相関が見えてきた例である。

二つ目の方法は、要因候補となる複数のプロセス変数を入力として製品品質を出力する予測モデルを作り、できたモデルを分析する方法である（図7の解決法2）。予測モデルには、線形回帰モデルあるいは非線形の機械学習モデルを用いる。得られたモデルを分析することで、各プロセス変数の貢献度合いを調べることができる。

いずれの手法においても、プロセスの知見を有効に生かして、関連性があるプロセス変数に絞って散布図を描いたり、予測モデルを作ったりすることが重要である。

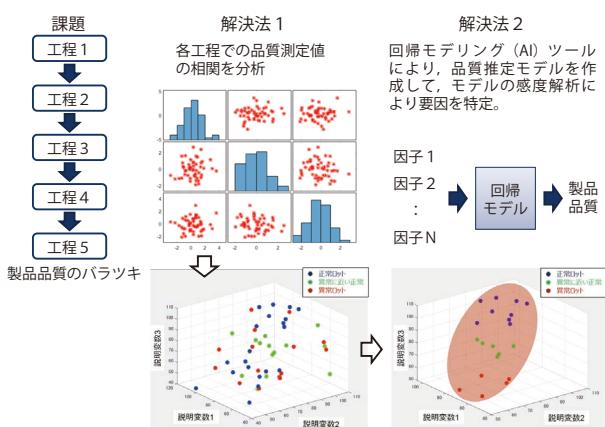


図7 品質異常の要因解析

## 7. 課題解決プロセス

AIによる一つの課題解決は、次の手順にしたがって、数週間から2,3ヶ月の期間で実施する。

- 課題特定・・・プロセスにおける課題をリストアップして、その影響度合いと難易度により優先順位をつけて、対象とする課題を決める。課題が解決された場合に、定量的な効果を示せることとデータが揃っていることが重要なポイントである。
- データ収集・・・利用できる情報とデータを揃えて、課題解決の目的を確認する。
- 仮説構築・・・課題解決に有効と思われる手法をリストアップして、これにも優先順位をつける。
- 解析・・・仮説に基づいて、データを整理して検証を行う。また、得られたデータをすべて使った網羅的な解析も実施して、両面から解を導く。
- 報告・・・最後に報告書を作成する。さらに派生した課題や改善案が導かれることが多い。なお、解析者とプロセス担当者が頻繁に打ち合わせを行い、お互いの知見を活かした結果を導くことが重要である。

## 8. おわりに

本章では、今後の展望について述べる。

### 8.1 シミュレータとの連携

利用できるデータが少ないと、AIにより期待される効果が得られないことが多い。そこで、できるだけ厳密なプロセスシミュレーションにより学習に必要なデータを生成する取り組みも行われている。そこで、様々な入力条件の組み合わせで、数千、数万、あるいはそれ以上のケースをシミュレーションして、生成されたデータを機械学習モデルに学習させる。学習後は、機械学習モデルにより高速に予測やケーススタディや最適化などのタスクを実行できる。

他にも、機械学習モデルがプロセスの異常を検知したとき、その対策を立案するためにプロセスシミュレーションを使うという役割分担も考えられる。

### 8.2 ロードマップ

AIは、プロセスデータを対象とした解析や予測の役割を果たしており、その最大の特徴は、ドメイン知識や解析スキルが乏しくても良い結果を導くことである。入力できるプロセスデータを準備すれば、AIが課題を解決するモデルを作り出してくれる。ただし、現状では、課題を特定して、それに必要なデータを選別するのは人であり、人が手をかけてAIを活用して結果を導いている（Human-Driven AI）。

今後は、AIが定期的にデータを調べて、課題を発見して解していく、AI主体の世界が作られていくと考えている（Data-Driven AI）。

さらに、AIが発見した知見を知識として獲得して、他のプロセスに対してもその知識を活用する時代が来るを考えている（Knowledge-Driven AI）（図8）。

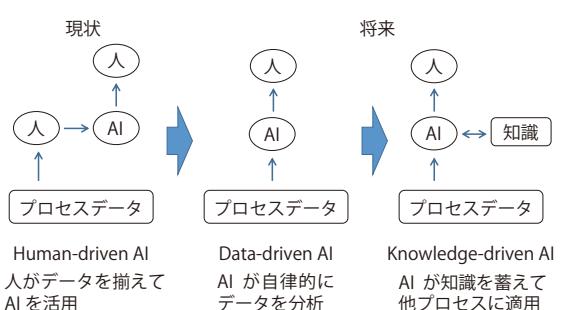


図8 AI活用ロードマップ

### 参考文献

- (1) 大谷哲也, “製造業におけるAI活用事例～人とマシンの協働のかたち”, 分離技術, Vol. 50, No. 2, 2020
- (2) Tetsuya Ohtani, “Digital data improvement,” Hydrocarbon Engineering, Vol. 25, No. 3, 2020, pp. 69-74
- (3) 舟津公人, 金子弘昌, ソフトセンサー入門：基礎から実用的研究例まで, コロナ社, 2014