

[事例実践論文]

# Human in the Loop Machine Learning (人間参加型機械学習) の運用のためのシステムアーキテクチャの定義と実践

## System Architecture Definition and Implementation for the Operation of Human in the Loop Machine Learning

新保 利弘<sup>†</sup>, 岡田 陽介<sup>‡</sup>, 藤本 敬介<sup>‡</sup>, 宇野 健人<sup>‡</sup>, 西村 秀和<sup>§</sup>, 松原 仁<sup>||</sup>  
Toshihiro SHIMBO, Yousuke OKADA, Keisuke FUJIMOTO, Kento UNO, Hidekazu NISHIMURA, Hitoshi MATSUBARA

<sup>†</sup> 三菱ガス化学株式会社

<sup>‡</sup> 株式会社 ABEJA

§ 慶應義塾大学

|| 東京大学

<sup>†</sup> Mitsubishi Gas Chemical Company, Inc

<sup>‡</sup> ABEJA, Inc

§ Keio University

|| The University of Tokyo

### 要旨

多くの企業がデジタルトランスフォーメーション (DX) を進める中, AI の積極的な活用が検討されている. しかし, 長年にわたる改善活動で進化してきた生産現場のプロセスに AI を導入する際には, 異常時のデータ取得の難しさや全データのセンシング不可能性などから, 高精度な機械学習モデルの構築が困難であり, 期待される精度とのギャップが大きな障壁となっている.

本研究では, このような課題の解決を目指し, Human in the Loop Machine Learning (HITL) の原理を活用して, 人間と AI の協調を実現する運用プロセスのアプローチを提案する. 具体的には, 化学企業の AI 腐食診断システムを事例に, HITL に基づく人間と AI の協調を含む運用環境のシステムアーキテクチャを定義し, 評価する.

開発ステージで完全に学習を終えなくても, 運用ステージでの人間と AI の協調を通じて, 運用・開発プロセスを連携させるアーキテクチャに基づき, 業務プロセスの中での AI の有効活用を実践的に報告する. 本研究は, AI を効果的に組み込むための新しいアプローチを提供し, 現場起点の考察を提供するものである.

### Abstract

As many companies are promoting digital transformation (DX), the active utilization of AI is being considered. However, introducing AI into manufacturing processes that have evolved through years of improvement activities presents significant challenges. These include difficulties in data acquisition during anomalies and the impossibility of sensing all data, making it challenging to build highly accurate machine learning models. Consequently, the gap between the expected and achievable accuracy becomes a major barrier.

This study aims to address these challenges by proposing an approach that leverages the principles of Human in the Loop Machine Learning (HITL) to realize a collaborative operational process between humans and AI. Specifically, we define and evaluate a system architecture for an operational environment that includes human-AI collaboration based on HITL, using an AI corrosion diagnosis system in a chemical company as a case study.

Even without completing the learning phase in the development stage, this study practically demonstrates the effective utilization of AI in business processes through human-AI collaboration in the operational stage, following an architecture that links the operational and development processes.

This research provides a new approach to effectively integrate AI and offers insights starting from the ground level.

## 1. はじめに

多くの日本企業は, 生産現場での創意工夫や市場動向に応じた持続的なプロセス改善を通じて進化してきた. 例として, 化学企業 D 社は, 2000 年に熟練作業者のノウハウをシステム化し, 生産性の向上を実現した[1][2][3]. このプロセスでは, 熟練作業者からのインタビューを通じて収集された膨大なノウハウが, エンジニアやその他の専門家による標準化を経て, プラント運転支援システムに統合された.

---

[事例実践論文]

2023 年 9 月 6 日受付, 2023 年 12 月 22 日改訂, 2024 年 2 月 14 日受理

© 情報システム学会

2012 年以降、機械学習、特にディープラーニングの進展は、計算能力の向上とデータの拡大に支えられ、入力から出力への複雑な写像を、できるだけ簡単な関数の組み合わせでかつパラメータ数を減らすような工夫を行いながら獲得することが可能となった[4]。これは、画像認識、自然言語処理、画像生成の分野における顕著な進歩に寄与している。機械学習技術の発展に伴い、化学プラントにおいても熟練工の代替としての活用が可能となった。

2015 年には、経済産業省によるデジタルトランスフォーメーション (DX) の推進が呼びかけられ、多くの企業が生産現場での機械学習の活用を検討し始めたが、既存の生産環境において機械学習を適用し成果を上げることは容易ではない。特に、化学プラントでは異常時のデータの不足、センシングの不完全などによりデータの偏りがあり、高精度の機械学習モデルの構築が困難である。Emmanouilidis は、機械学習のアプローチは課題定義とデータが豊富な場合は効果的だが、生産環境では問題が多いと指摘している[5]。実際、生産環境における機械学習 (本稿では教師あり学習を前提とした機械学習とする) モデルの精度向上を目的とした PoC (実証実験) は行われているが[6][7]、機械学習に基づく運用システムの事例は少ない。

この問題に対処するため、機械学習の推論結果を人間が確認し、改善を図る「Human in the Loop Machine Learning 以下 HITL」が提案されている[8]。さらに、HITL を活用した人間の支援を受けながら運用するシステムに関する最新の研究によれば、機械学習モデルの訓練と評価プロセスにおいて、人間の知識と判断をどのように統合するか、人間のフィードバックを活用することで、機械学習モデルは継続的に改善することについて言及している[9]。しかし、機械学習を適用して実装していく開発・テスト・訓練に関する方法論は確立されておらず[10]、これまで実践的に HITL を活用したシステムアーキテクチャの提唱は見当たらない。

本研究では、開発ステージにおいて、高精度の機械学習モデルの構築や運用ステージにおいても 100%の精度を達成することが難しいという背景の中で、化学企業のプラントにおける腐食配管の検査システム (以下 AI 腐食診断システム) を事例として、HITL を活用した人間と AI の協調を運用プロセスに取り入れるための詳細なアーキテクチャの定義と実践を行った。AI 腐食診断システムでは、機械学習だけでは要求される精度を達成することが困難であるため、人間と AI の協調を取り入れたシステムアーキテクチャを定義した。このシステムは熟練作業者の専門知識に基づいてモデルを学習させ、69%の予測精度を達成し、化学企業に実装され、人間と機械学習モデルの協調による運用により、人間の作業負荷を約 50%削減した。機械学習モデルの精度向上に用いた HITL のシステムアーキテクチャの効果はまだ明らかではないが、HITL の運用から得られた実践的な考察を報告する。

本論文の構成は、第 2 章で HITL を適用したシステムとシステムアーキテクチャについて述べ、第 3 章では、具体的に HITL を適用した AI 腐食診断システムのアーキテクチャを定義する。第 4 章では、AI 腐食診断システムに対するアーキテクチャの適用結果を検証し、人間と AI の協調から得られた考察、さらにシステムアーキテクチャの他事例への適用可能性について論じる。第 5 章で結論を述べる。

## 2. HITL を適用したシステムとシステムアーキテクチャ

一般的な機械学習の開発プロセスは、デジタルデータの蓄積、データラベリングや前処理 (アノテーション)、機械学習モデルへの学習、推論による精度検証という流れである。本論文では、このプロセスを一度行うことを PoC (Proof of Concept, 実証実験) と定義し、複数回の PoC を繰り返すことで機械学習を適用したシステムの運用に至るプロセスを図 1 に示す。



図 1 一般的な機械学習を適用したシステム開発と運用のプロセス

生産環境における機械学習の推論結果のみに依存するシステムでは、高精度のモデル開発が必要となり PoC の回数が増えることが予想される。このような課題を解決するために、HITL の導入が考えられる。本論文では、HITL の機械学習モデルの判定に人間が関与し、機械学習モデルを運用しながら、モデルを改善していくプロセスを定義した。

既存の HITL に関する研究では、「データフローの一部は自動化しつつも、生産プロセスにおいては人間の認知能力を効果的に統合することが求められている」とされている[5][9]。また、「人間のスキルを社会工学的システムに統合するには、システムに人間を参加させるアプローチが必要である」と指摘されている。さらに、「技術的システムの操作においては人間の貢献が重要でありながら、その側面は十分に検討されていない」との見解も示されている[5]。これらの指摘は、「生産環境では、効果的な HITL の方法を開発するためにはさらなる研究が必要である」という結論に繋がる。

生産環境に HITL を適用したシステムを構築する際には、対象となるシステム明確にし、その全体像を把握することが重要である。対象システムを明確にするためには、システムズエンジニアリングアプローチに基づくシステムアーキテクチャの定義が有効である[11][12][13]。このアプローチでは、対象システムと外部システムとの関係を明確にし、対象システムが持つべき機能を定義し、論理的にシステム要素に分解し、それらの関係性を定義する。システムアーキテクチャの定義においては、対象システムの機能と HITL の関係性を明確にすることが重要である。

本論文では、これまで概念として言われていた HITL について、具体的なシステムアーキテクチャとしての定義を試みた。提案するシステムアーキテクチャでは、人間と機械学習の推論結果が連携して運用される HITL を採用している。例えば、機械学習の推論結果の精度が 60%であっても、運用段階で残りの 40%を人間が補助するという考え方である。このシステムアーキテクチャのコンセプトイメージを図 2 に示す。

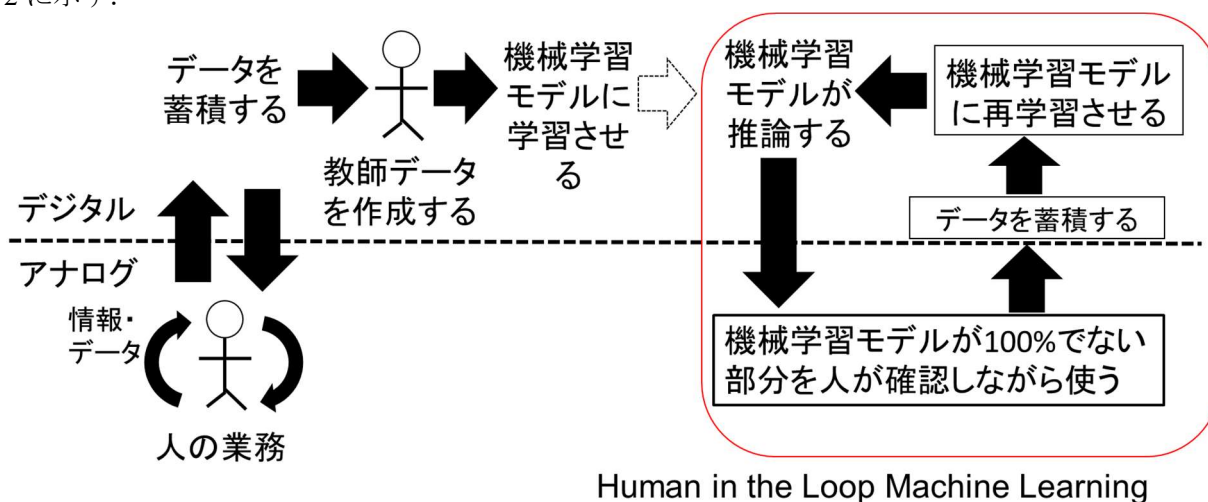


図 2 システムアーキテクチャのコンセプトイメージ

次章では、AI 腐食診断システムの事例を通じて、人間と AI の協調の運用を具体化し、対象システムの要求定義や基本機能の定義を踏まえた上で、HITL を適用したシステムアーキテクチャの定義について詳述する。

### 3. HITL を適用した AI 腐食診断システムのアーキテクチャ定義

三菱ガス化学新潟工場は、海風の影響などによりプラントにとって厳しい外部腐食環境が発生しており、最も重要な保安業務である外部腐食配管の検査業務を長年、人手で実施してきた。検査内容としては、各配管の設置場所に精通した運転員が配管の腐食箇所の画像を撮影し、保守員（熟練者）が画像を確認して対策を判断していた。プラントの保安のためには、点検時の見落としを防ぐことが最も重要であり、撮影された画像の枚数は非常に多く、運転員と保守員の作業負担を軽減することが大きな課題であった。さらに、検査結果は主観的なものであり、改善の余地は大きいと考えられた。配管外面の腐食検出に機械学習を適用したシステム開発の事例[6][7][14][15][16]は存在するが、適用に関しては確認されていない。本研究において、HITL を適用したシステムアーキテクチャが有効に機能するかを検証する。HITL を適用したシステムを構築するために、運用において人間と機械学習の推論結果を連携させることを考え、機械学習の推論結果が誤っていた場合には人間が修正し、機械学習モデルが再学習するプロセスを取り入れた。対象システムのイメージを図 3 に示す。

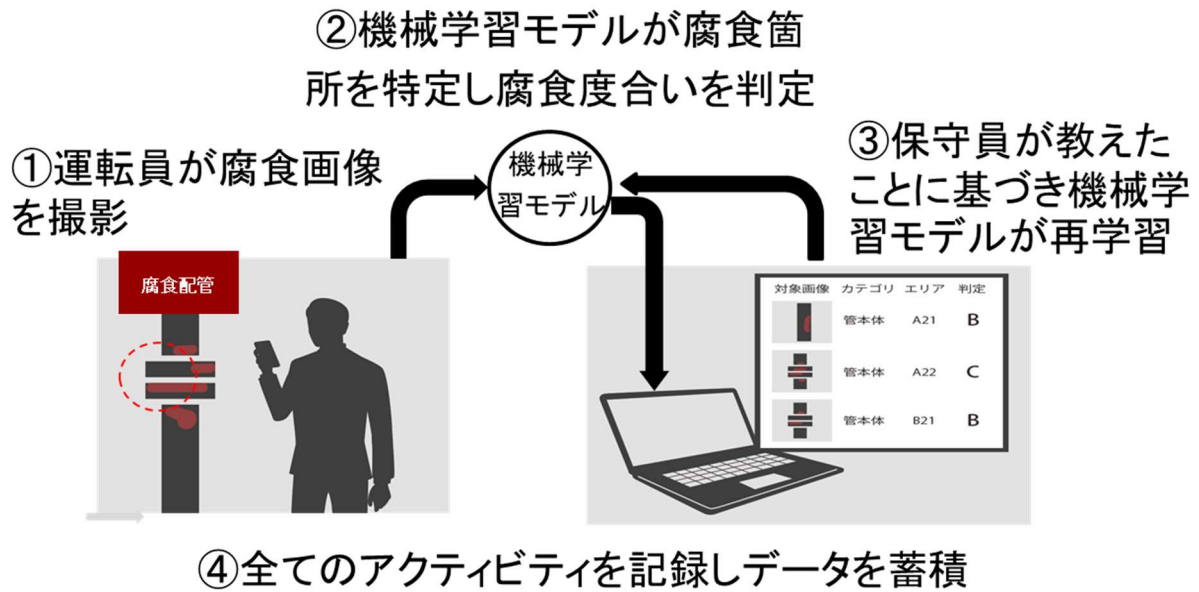


図3 対象システムのイメージ図

図3に示すように、運転員が腐食画像を撮影し、機械学習モデルが腐食箇所の特定制と腐食度合いの判定について推論を行った後、その結果を保守員が確認し、推論結果が誤っていた場合は保守員が修正し、その結果を再学習させる。

本システムを構築するためのシステムアーキテクチャの定義を行う。

### 3.1. AI 腐食診断システムの定義

図3を基に、本システムが求める機能性を表したものが図4のユースケース図である。

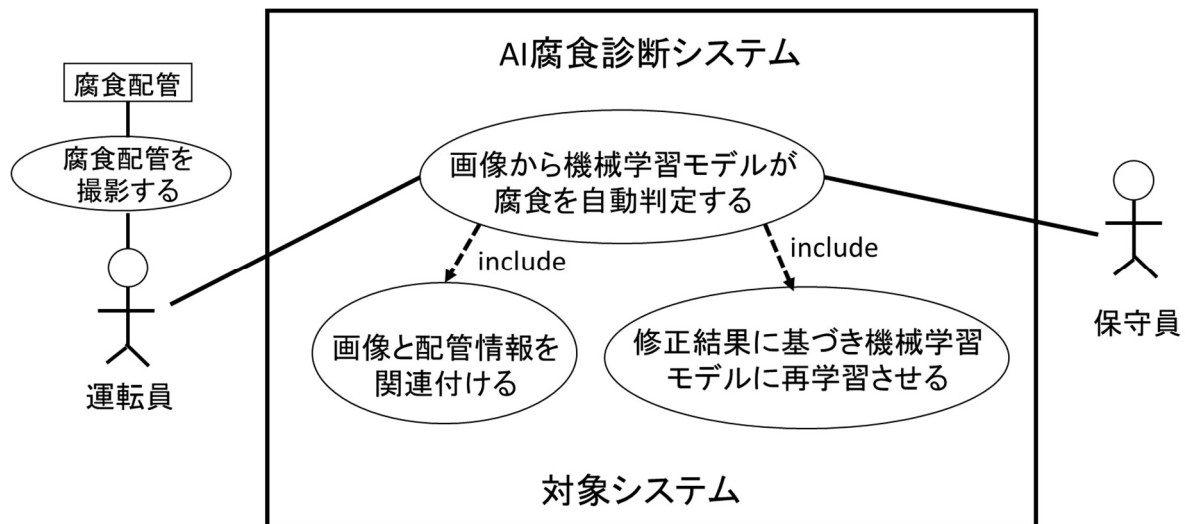


図4 AI 腐食診断システムの機能性の定義

図4では、AI 腐食診断システムの機能性は「画像に基づく腐食の自動検出」、「画像と関連情報のリンク」、「修正結果に基づく機械学習モデルの再学習」であることを表している。図4のAI 腐食診断システムの基本的な機能性を、「画像から腐食領域を判定する」と定義し、運転員、保守員と対象システムの相互作用を定義したものが図5である。

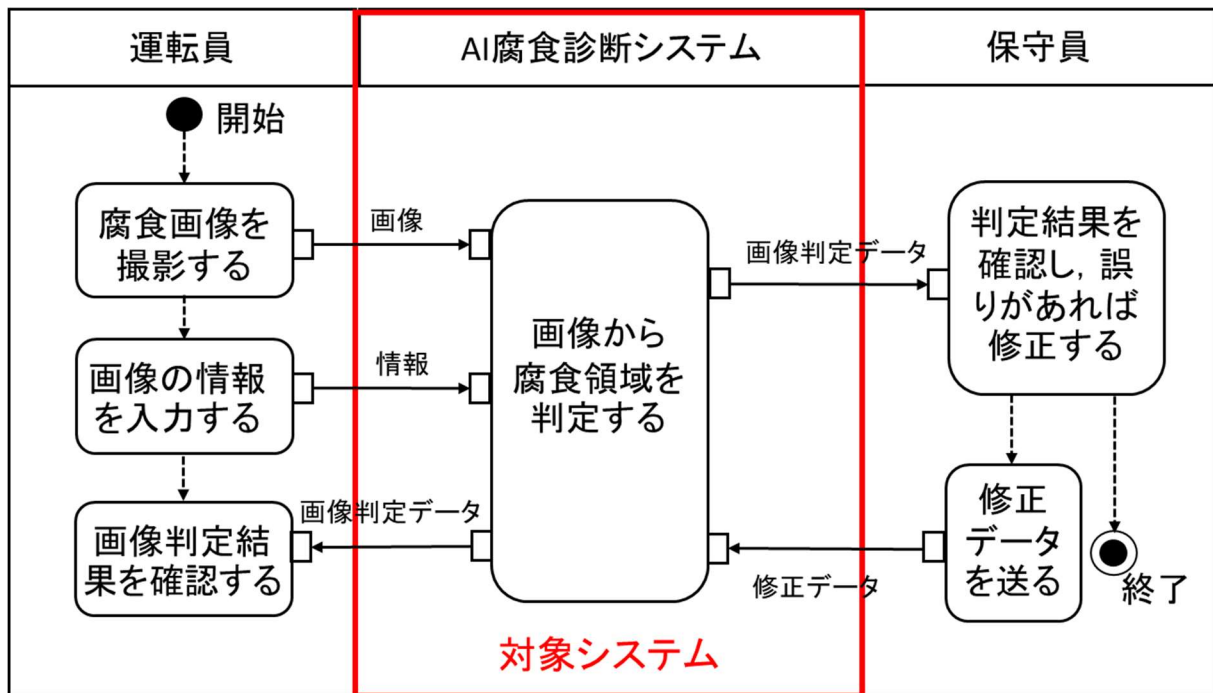


図5 AI腐食診断システムと運転員、保守員の相互作用

図5では、運転員が腐食画像を撮影し、画像と対象配管の情報をAI腐食診断システムに送り、AI腐食診断システムは画像から腐食領域を判定する。保守員は判定結果を確認し、誤りがあれば修正し、修正データがAI腐食診断システムに送られる。運転員も画像判定結果を確認することができる。図4に示す機能を実現するために、AI腐食診断システムは、機械学習モデルの管理・実行を行うAIサブシステムとデータの管理を行うマスタサブシステムの2つのサブシステムに分解し、より詳細な定義を試みた(図6)。

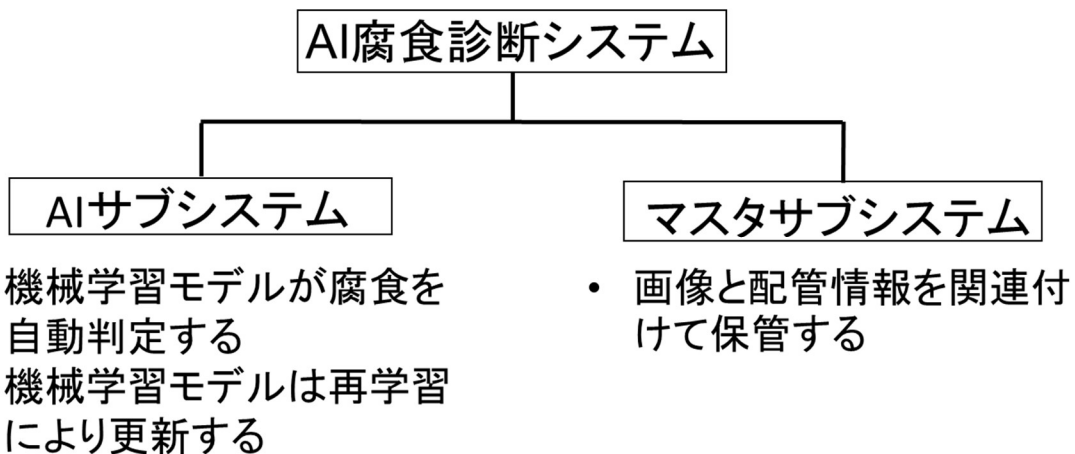


図6 AI腐食診断システムの分解

図5のAI腐食診断システムの基本機能「画像から腐食領域を判定する」を図6のAIサブシステムとマスタサブシステムの二つのサブシステムに分解し、運転員・保守員と対象システムとの相互作用を定義した機能フロー図を図7に示す。図5のAI腐食診断システムの部分を詳細化したものが図7のAIサブシステムとマスタサブシステムの部分になる。

図7は機械学習モデルの運用中にHITLを組み込んだものである。まず、運転員から腐食画像と画像の情報がマスタサブシステムに送られ、画像と情報を関連付けて保管する。次に、画像データはAIサブシステムに送られ、腐食を自動判定する。画像判定データは、マスタサブシステムを介して運転員と保守員に送られる。運転員が画像判定結果を確認することにより、腐食判定スキルを向上させる狙いがある。保守員は判定結果を確認し、誤りがあれば修正する。修正されたデータは、マスタサブシステムを介してAIサブシステムに送信される。AIサブシステムはこれらの修正に基づいて再学習し、機械学

習モデルを向上させる。このように、マスタサブシステムを経由して、保守員の評価を機械学習モデルに組み込むことにより、検査品質が向上する。図7に示されたアーキテクチャにより、AI腐食診断システムは運転員、保守員、AIサブシステム、マスタサブシステムが連携して働くことにより、効率的に腐食箇所の検出と腐食領域の判定、判定精度の向上を図ることができ、継続的な学習と改善が可能であると考えられる。

図7のアーキテクチャにおいて、機械学習モデルを向上させるためには、修正データを学習する機能が必要である。学習ステージでは、機械学習モデルを差し替えるものを作っており、運用ステージで機械学習モデルの開発が発生して、機械学習モデルを差し替えるために再学習するというプロセスがアーキテクチャで表現されなければならない。次項では図7のアーキテクチャの詳細化を行う。

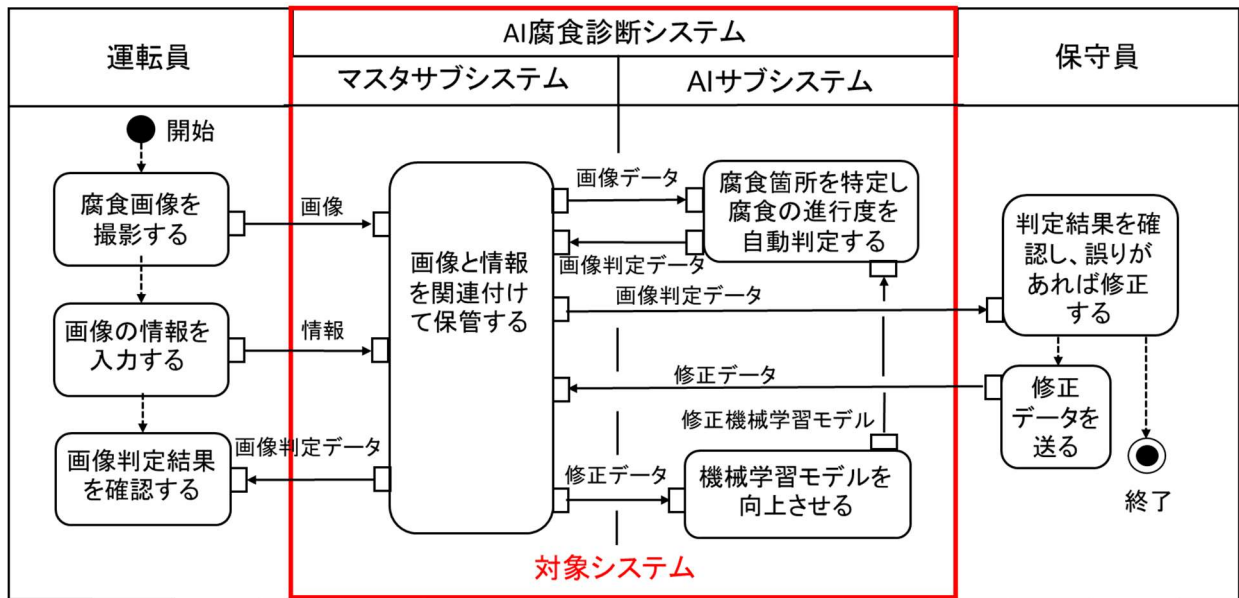


図7 AI腐食診断システムの機能フロー図

### 3.2. アーキテクチャの詳細な定義

図7のAI腐食診断システムのアーキテクチャは、最終的に実現される機能を定義しているが、実際の HITL を適用したシステムのアーキテクチャでは、関係する運転員や保守員がどのような役割を果たし、期待されるシステムを実現するのかの詳細を定義する必要がある。

図7に示すように、運用ステージで機械学習モデルを向上させるということは、保守員が修正した新しいデータを用いてAI腐食診断システムが再学習し、機械学習モデルを改変していくことを意味する。そのためには、運用プロセスの中で機械学習モデルの開発が発生すること、すなわち再学習して機械学習モデルを差し替えていくプロセスが必要である。

この視点を含め、図7のAI腐食診断システムの特にAIサブシステムの部分の詳細化を行い、運転員、保守員とエンジニアが対象システムとどのように振る舞うかを詳細に定義したものを図8に示す。

図8ではAIサブシステム内で運用と開発が連動していることが記述されている。図8に示すように、AI腐食診断システムのアーキテクチャの詳細は、運転員が腐食画像と画像の情報をマスタサブシステムに送り、画像と情報を関連付けて保管する。マスタサブシステムからAIサブシステムが画像データを受け取り、腐食箇所を特定し腐食の進行度を自動判定し、その判定データを評価する。ニューラルネットワークの関係上、データの判定が不正なもの（例えばマイナス値など）もあるため、判定データを評価する必要がある。判定データはマスタサブシステムに送られ、保守員が判定データを確認し、誤りがあれば修正して修正データをマスタサブシステムに送り、修正データを保管する。ここまでは運用の中で行われる手順である。さらに開発を進めるためには、マスタサブシステムからAIサブシステムに修正データが送られ、エンジニアがAIサブシステム上で機械学習モデルを改変し、改変された機械学習モデルが評価されて配置され、腐食度合の判定に活用される。

このように、図8のアーキテクチャでは、対象システムであるAI腐食診断システムの機能とAI腐食診断システムと HITL の関係性が明確に定義されている。その結果、仮に機械学習の推論結果の精度が60%であったとしても、人が残りの40%を補正し、補正に基づいて再学習する HITL の概念を取り入れたプロセスを含むシステムアーキテクチャとして定義できている。

AI 腐食診断システムに用いられている機械学習モデルの構築プロセスについて説明する。既存のリアルタイム物体検出モデルである YOLOv7 をベースに腐食画像を用いてエンジニアがファインチューニングを行った。YOLOv7 は 2022 年 7 月に公開[17]されたものであり、5FPS から 160FPS の範囲で速度と精度の両方ですべての既知のリアルタイム検出モデルを上回り、速度と精度の面で必要十分な性能を発揮できることから採用に至った。

次章では、このアーキテクチャに基づいて開発された AI 腐食診断システムに対するシステムアーキテクチャの適用結果について述べる。

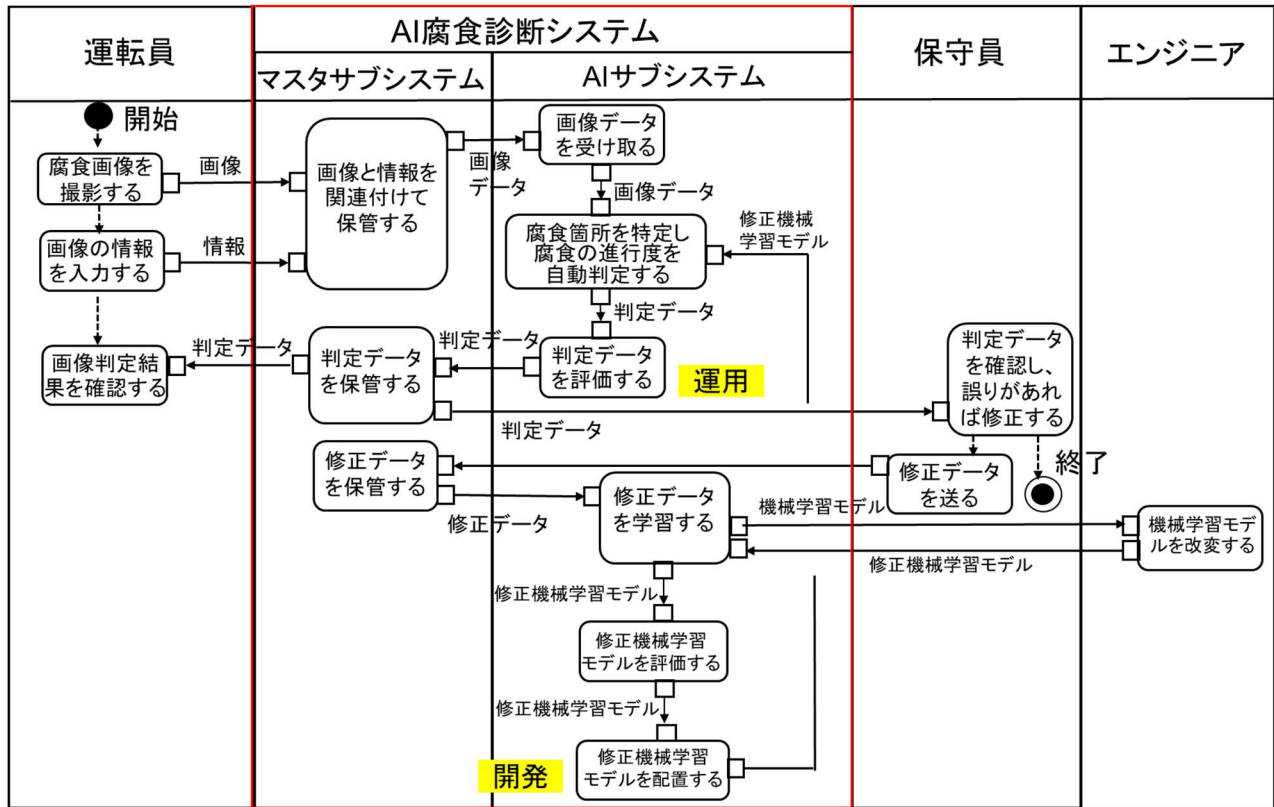


図 8 AI 腐食診断システムのアーキテクチャの詳細化

#### 4. AI 腐食診断システムに対するシステムアーキテクチャの適用結果


##### 4.1. AI 腐食診断システムの検証結果

第 3 章で定義したシステムアーキテクチャを基に、AI 腐食診断システムを設計、開発し運用に至った。このシステムは、炭素鋼とステンレス鋼の配管を対象としており図 9 に示すように、配管の画像から機械学習モデルによって特定された腐食箇所とその進行度を確認できる。

機械学習モデルは、画像からの腐食部位を矩形で検出 (Object Detection) し、腐食の進行度を評価する。AI サブシステムによる評価結果と保守員による確認結果を表 1 に示す。

Recall (再現率) とは、保守員が正と診断したデータに対して、機械学習がどれだけ正と判定できたかを示す値である。Precision (適合率) とは、機械学習が正と判定したデータに対して、保守員がどれだけ正と診断したかを示す値である。精度は Recall (再現率) と Precision (適合率) の調和平均である。AI サブシステムが判定データを評価し、保守員が確認する段階の Recall (再現率) は約 70%であった。

表 2 には、炭素鋼腐食配管における各腐食レベルの機械学習モデルの判定結果と保守員の診断結果の比較を示す。



: 重度の腐食   
  : 軽度の腐食

図9 AIが画像から腐食した部位と腐食の進行度を設定した様子

表1 腐食配管における機械学習モデルの推論結果

	判定度合い	F 値(精度)	Recall (再現率)	Precision (適合率)
炭素鋼腐食配管	5段階	69%	69%	70%
ステンレス鋼腐食配管	4段階	74%	72%	84%

表2 炭素鋼配管の各腐食レベルの保守員の診断結果と機械学習モデルの判定結果の比較

	単位: 枚	機械学習モデルの判定結果					Recall	一段階 重大	Recall+ 一段階 重大
		A	B	C	D	E			
保守員 の 診 断 結 果	A	108	24	1	0	0	81%	—	81%
	B	68	150	24	0	0	62%	28%	90%
	C	13	88	254	21	1	67%	23%	91%
	D	0	4	83	137	7	59%	36%	95%
	E	0	0	4	9	30	70%	21%	91%
	Precision	57%	56%	69%	82%	79%			90%
一段階 軽微	36%	33%	23%	5%	—				
Precision +一段階 軽微	93%	89%	92%	87%	79%	88%			
Recall: 保守員の診断結果に対する機械学習の判定の再現率									
Precision: 機械学習の判定結果に対する保守員の診断結果の比率									

表2では、縦軸が保守員の診断結果、横軸が機械学習モデルの判定結果を表す。腐食の深刻度は、Aが重度の腐食、Bが腐食、Cが軽度の腐食、Dが錆びた外観、Eが塗装の剥離である。マトリックスの



対角線上 (A と A, B と B など) が保守員の診断結果と機械学習モデルの判定結果が一致した画像枚数である。

腐食診断の特性上、重大な腐食度の診断に重きをおく再現率 (Recall) に信頼を置いた上で、適合率 (Precision) を検討すべきであると考えられる。

再現率 (Recall) に対して一段階重大とは、保守員が B と診断したが機械学習モデルが A と判定した場合のように、保守員の診断結果に対して機械学習モデルの判定結果が 1 ランク重大な側にずれている割合を示す。腐食診断においては、機械学習モデルによる厳しい診断が運用上問題ないと考えられている。これを踏まえた場合、再現率 (Recall) に一段階重大な値をプラスすると、AI 腐食診断システムの運用における保安レベルは約 90%の精度と考えられる。

適合率 (Precision) に対して一段階軽微とは、機械学習モデルが A と診断した結果に対して保守員が B と判断した場合のように、機械学習モデルに対して保守員が 1 ランク軽微な側にずれている割合を示す。機械学習モデルに対して保守員が軽微な判定をした一段階軽微は運用上は問題ないと考えられ、適合率 (Precision) に一段階軽微な値をプラスすると、AI 腐食診断システムの運用における保安レベルは約 88%の精度と考えられる。したがって、AI 腐食診断システムの運用における保安レベルは約 90%の精度と考えられる。

炭素鋼の開発では、開発ステージで7人の保守員が3,800枚の画像に対してアノテーションを行った。アノテーションの一貫性を確保するために評価基準を標準化し、教師データの品質を向上させる試みを行った。しかしながら、判定 B と判定 C の境目は難易度が高く若干のばらつきがあり、100%の標準化は実現できないことが判明した。また、時間の経過とともに評価基準の一貫性にばらつきが出ることが懸念される。今後、修正データが蓄積され再学習が必要になる際、評価基準の再確認や複数の保守員によるアノテーションの確認が重要である。

今後は、運用の経験から、現行の5段階のクラス分け (A, B, C, D, E) をよりシンプルな3段階 (A+B, C, D+E など) に再定義することで、診断の一貫性が向上し、機械学習モデルの精度が向上することが考えられる。

## 4.2. AI 腐食診断システムの導入に伴う作業効率化と学習効果に関する考察

本研究では、AI 腐食診断システムの導入が運転員および保守員の作業効率に及ぼす影響を分析した。具体的には、運転員と保守員の作業量を分析し、AI 腐食診断システムによる画像入力作業の削減や診断シートの起票時間の短縮を確認した。また、運転員と保守員の合計 50 人を対象にインタビューを行い、実際の作業体験に基づく意見を収集した。

- (1) 機械学習モデルの精度が 69%でも、保守員はシステムを問題なく利用することができた。
- (2) 運転員の画像入力時間が 3 分から 1 分に短縮された (67%の削減)。画像入力時間の短縮は、特に Excel 管理からシステム化への移行によるもので、画像ファイルの選択や設備情報入力の自動化が主な要因であった。
- (3) 保守員の作業量も 30%減少した。機械学習モデルの再現率が 69%であるが、機械学習モデルが矩形付けと腐食の診断を行った確認作業は、作業時間の短縮に寄与した。保守員にとっては腐食画像をそのまま見るよりも、69%の再現率であっても一度機械学習モデルが矩形付けと腐食度の診断を行ったものを見る方が作業時間については 30%減少した。保守員が配管の腐食をチェックする際、機械学習モデルによって腐食部分だと思われる個所がマーキングされた画像を使う方が何もマーキングされていない元の画像を見るよりも業務効率が高まるという結果になった。
- (4) AI 腐食診断システムでは、運転員が撮影した腐食画像と画像の情報を入力して「AI の判定を行う」というラジオボタンをクリックすると、1~3 秒ほどで機械学習モデルの判定結果を表示することができる。機械学習モデルの判定結果を直接、運転員が毎回見ることができることは、運転員への教育効果の向上が示唆された。運転員が機械学習モデルの判定結果から学ぶことにより、手動の画像検出の精度が向上する可能性がある。AI 腐食診断システムは、熟練者である保守員がアノテーションを行っており、機械学習モデルの診断は保守員のスキルと言える。運転員の画像診断のスキルは保守員と比べ低いが、機械学習モデルの診断結果を毎回見ることにより、抽出しなければならぬ腐食配管に関する感度が向上し、撮影すべき配管が分かってくるという意見があった。その結果、漏れなく腐食配管の画像を撮影し、AI 腐食診断システムに入力することが可能となり、画像検出の精度が向上していくものと考えられる。
- (5) 保守員と運転員の両方で機械学習モデルの判断に対する関心が高いため、今後、人間と機械学習モデルとの協調が大きく進み、安全対策がさらに向上することが期待される

- (6) 将来的には、配管の肉厚測定などの実データを用いた再アノテーションにより機械学習モデルの精度向上を目指している。
- (7) 蓄積されたデータは、工場内の腐食トレンド分析や予測に役立つと考えられる。
- 以上の結果から、AI 腐食診断システムの導入は、作業効率の向上とともに、運転員の教育や安全対策の向上に貢献する可能性があることが示された。

### 4.3. 人間と機械学習モデルの協調から得られた考察

#### 4.3.1. 再学習の結果と HITL に関する考察

AI 腐食診断システムは、熟練した保守員が選んだ 3,800 枚の画像を用いて開発された。運用中の再学習プロセスでは、機械学習モデルと保守員の診断に 110 件の不一致が見られた段階で、これらを機械学習モデルが再学習した。しかし、再学習後の機械学習モデルの精度は、再学習前と比較して改善されなかった。この理由は、再学習に使用されたデータ量が元の学習データに比べて少なかったためと考えられる。

この問題を解析するため、異なる数量の学習画像を用いた際の機械学習モデルの精度を評価した。1,000 枚の画像を使用した場合、精度は 60%であった。学習データ数が 1,500 枚に増えると、精度は向上したが、それ以上のデータ量では精度の向上が見られなかった。これは、1,000 枚から 1,500 枚の増加が再学習データの影響を反映していると考えられる。現在の機械学習モデルは、3,800 枚の画像で学習されているため、大量の再学習データを収集しない限り、再学習の効果は限定的であると考えられる。さらに、再学習データの作成には保守員の関与が必要であり、そのため機械学習モデルの精度が 100%に到達することは困難と考えられる。

HITL の実装は、初期段階の機械学習モデルの精度が低い場合でも本番運用を進めることを可能にしている。このアプローチでは、保守員が機械学習モデルの限界を補い、初期段階で効果を発揮するように設計されている。本研究のアーキテクチャにはこの設計思想が取り入れられており、機械学習モデルとその再学習だけではなく、AI 腐食診断システム全体の効能にも焦点を当てている。HITL の主要な利点は、機械学習モデルの初期精度が低くても本番運用を続行できることにある。これを実現するためには、AI 腐食診断システム全体が効能を生み出すよう設計する必要がある。

本研究では、機械学習モデルを 69%の精度で実装した。AI 腐食診断システムは、この精度の不足を補うように設計されている。運用の結果、再学習用のデータがまだ十分に蓄積されていないことがわかった。そのため、一見すると HITL (Human in the Loop) が機能していないように見えるが、十分なデータが蓄積されれば、機械学習モデルの精度はさらに向上すると考えられる。

また、ステンレス鋼管を対象とした機械学習モデルの運用においては、開発時に定義した 4 段階の腐食度とは異なる程度の腐食が観察された。これらに対応するため、既存の機械学習モデルに新しいモデルを追加することを検討している。このような新しいタイプの課題が追加された場合、データセットを更新して新たに学習することでこれに対応できることも HITL の利点の一つである。今回の研究では、そのような拡張は想定外であったが、HITL のコンセプトとしては重要な要素と言える。HITL を採用していないと、以下のような価値を失う可能性がある

- ・ 100%の精度でなくても保守員が担保できること
- ・ 再学習により精度が向上するという思想
- ・ 機械学習モデルの精度が低くても業務効率化を実現するマスタサブシステムの構築

さらに、現場のヒアリングから分かったことは、機械学習モデルを用いることの「面白さ」も重要な要素である。単なる業務の遂行を超えて、機械学習モデルを使った腐食判定に直面することは、運転員、保守員のモチベーション向上や学習につながると言える。

#### 4.3.2. 機械学習モデルの判定と人間の診断に関する考察

実際の保守員と機械学習モデルの共同作業 (HITL) の結果、機械学習の判定と保守員の診断に不一致が見られたのは、剥離部分の種類に関する認識の違いによるものであった。具体的には、塗装剥離と減肉剥離の診断における違いが原因であることが示唆された。保守員は、画像を基にこれら二つを区別できるが、機械学習モデルには二つの区別ができなかった。現在の運用では、機械学習モデルが検出した剥離画像を保守員が確認し、その種類を決定している。将来的には、異なる剥離タイプを認識できる機械学習モデルの開発により、精度のさらなる向上が期待される。

### 4.3.3. 開発と運用の画像の質の違いにより判明した課題

AI 腐食診断システムの運用開始後、新たな課題が明らかになった。開発段階で用いた理想的な腐食画像と、実運用時に運転員から得られた実際の腐食画像との間で画質の違いが存在する。この画質の差異は、特に再学習時の精度向上を妨げる要因にもなっていると考えられる。運用時には、対象配管が不鮮明な画像も含まれ、これはノイズに起因すると考えられる。この問題を解決するためには、撮影方法の改善が必要である。

### 4.3.4. AI 腐食診断システムのアーキテクチャの他事例への汎用性について

現実社会では、HITL を用いたシステムの需要は高まっており、これらのシステムアーキテクチャを明確に定義し、汎用化する必要がある。HITL を活用したシステムの基本機能は、「機械学習モデルによるデータの推論」、「データと情報の関連付けと保管」、「修正結果を基にした再学習」と定義できる。具体的には、このシステムは「AI サブシステム」と「マスタサブシステム」の二つの部分から成り立っている。AI サブシステムは、「機械学習モデルによるデータの推論」と「機械学習モデルの向上」を担当し、マスタサブシステムは「データと情報の関連付けと保管」を行う。機能フローとしては、データや情報がまずマスタサブシステムに送られ、そこで画像と情報を関連付けて保管する。次に、画像データは AI サブシステムに送られ、機械学習モデルが推論を行う。この推論結果はマスタサブシステムを通じて人間によって確認され、誤りがあれば人間が修正し、AI サブシステムにフィードバックされる。これによって機械学習モデルの精度が向上し、次の推論ではより高い診断精度が得られるようになる。このアプローチは、他の事例にも適用可能である。

図 10 に、人間の評価を取り込むことで AI サブシステムの機械学習モデルを向上させ、自動化と効率化を実現していくシステムアーキテクチャを示す。

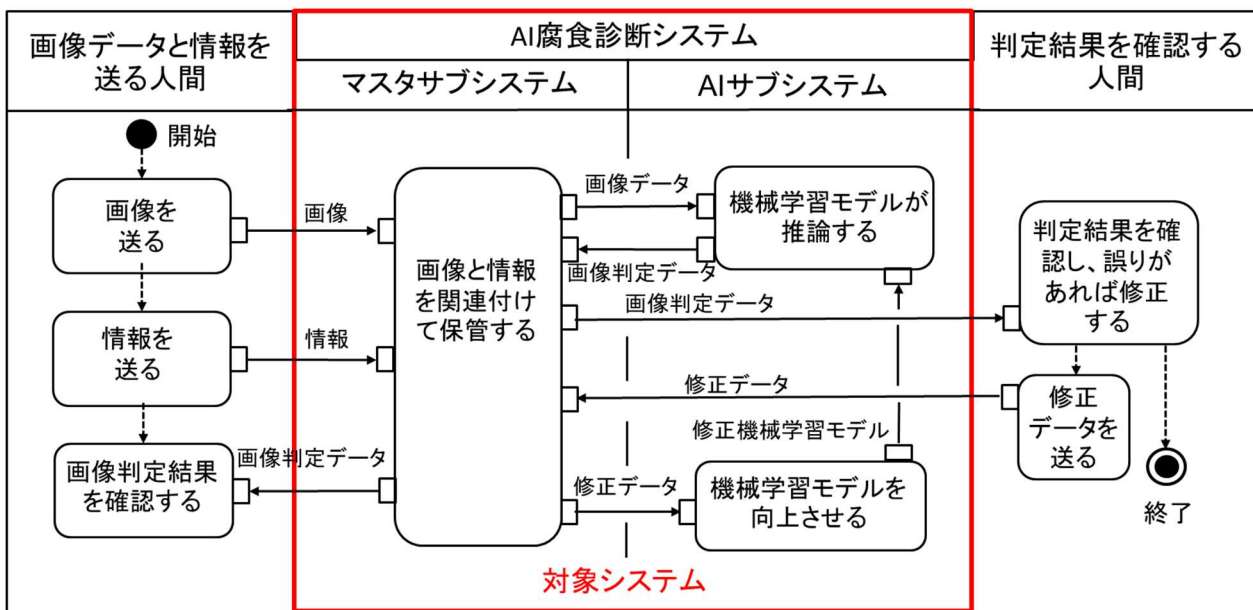


図 10 機械学習モデルの推論と人間が協調したシステムのアーキテクチャ

## 5. 結論

本研究では、Human in the Loop Machine Learning(HITL)を活用した AI 腐食診断システムの開発と運用について論じた。HITL の運用から得られた実践的な考察も報告した。具体的には、化学プラントの配管の腐食を外観検査するために、人間と機械学習モデルが協調して機械学習モデルの精度を向上させる運用プロセスを考案した。このプロセスはアーキテクチャとして定義され、実際の工場に実装された。

AI 腐食診断システムの導入による効果は、69%の予測精度を実現し、同時に人間の作業負荷を 50%削減した。さらに、人間と機械学習モデルの協調による運用は、安全性に関する貴重な洞察を提供した。運用段階では、運用と開発プロセスの連携に基づいたアーキテクチャを用いて HITL が効果的に機能することを目指した。機械学習モデルの経時的な精度向上の効果はまだ完全には明らかではないが、今後の HITL モデルの改良を通じて、その効果をさらに高めることを目指している。HITL の運用では、保安業務の実践と機械学習モデルの診断に焦点を当てることにより、人間の経験と機械学習モデルが協調して新たな価値を生み出すと考えられる。機械学習モデルを活用した腐食診断システムの提案には、人間

と機械学習モデルの協調, 具体的な課題への対応, 人間の経験を運用に取り入れることが不可欠である。運用中の再学習による機械学習モデルの精度向上だけでなく, 人間の経験をシステムの運用に取り入れることが AI 腐食診断システムの成長に重要であると考えられる。機械学習モデルによる診断と安全運用の実践を検証することで, 実運用に基づく人間と機械学習モデルの協調の重要性とそれが生み出す新たな価値を実証した。

本研究では, 以前から言われていた HITL の概念を具体化し, アーキテクチャを構築して現場での運用を通じてその効果を検証した。これは, PoC 段階で高精度の機械学習モデルを実現することが難しく, システムとしての実装が進まないという課題に対して, HITL のシステムアーキテクチャを通じて貢献するものである。

## 謝辞

AI 腐食診断システムの開発にご尽力いただきました(株)ABEJA の皆様, 三菱ガス化学(株)新潟工場の皆様には厚く御礼申し上げます。

## 参考文献

- [1] 小河義美, “プロセス製造の効率化と知的統合生産システム,” 化学経済, Vol.53, No.2, 2006, pp.91-98.
- [2] 小河義美, 安藤隆彦, “次世代型化学工場への挑戦～その実際と生産革新手法～,” 計装, Vol.48, No.7, 2005, pp.17-23.
- [3] 松島茂, 株式会社ダイセル, “ダイセル式生産革新はこうして生まれた,” 化学工業日報社, 2016.
- [4] 松尾豊, “ディープラーニングと進化,” The 31st Annual Conference of the Japanese Society for Artificial Intelligence, 2017, pp.1-4.
- [5] Christos, E., Petros, P., Luka, B., Vassilis, K., Apostolos, F., Christos, K., Cristobal, R. “Enabling the Human in the loop: Linked Data and Knowledge in Industrial Cyber-Physical Systems,” Annual Reviews in Control, vol.47, 2019, pp.249-65.
- [6] 秦央彦, 佐伯隆, 守屋泰弘, 今村彰太郎, “画像データの解析による配管外面腐食診断システム,” 第 49 回石油・石油化学討論会 (山形大会), 2019, pp.132-134.
- [7] 田中達也, 武田和宏, “AI を用いた配管の自動認識による管理対象選択手法の開発,” 第 63 回自動制御連合講演会, 2020, pp.1190-1191.
- [8] Under Secretary of Defence for Acquisition Technology, “DoD Modeling and Simulation (M&S) Glossary DoD 5000.59-M”, U.S. Department of Defense, 1998.
- [9] Xingjiao, W., Luwei, X., Yixuan, S., Junhang, Z., Tianlong, M., Liang, H., “A survey of human-in-the-loop for machine learning,” Future Generation Computer Systems, vol.135, 2022, pp. 364-381.
- [10] 丸山宏, 城戸隆, “機械学習工学へのいざない,” 人工知能, Vol.33, No.2, 2018, pp.124-131.
- [11] 西村秀和監訳, “システムズエンジニアリングハンドブック 第 4 版,” 慶應義塾大学出版会, 2019.
- [12] Friedenthal, S., Moore, A., Steiner, R., 西村秀和監訳, “A Practical Guide to SysML – The Systems Modeling Language, システムズモデリング言語 SysML,” 東京電機大学出版局, 2012.
- [13] 新保利弘, 西村秀和, “プロジェクト構想段階へのシステムアーキテクチャ定義の導入,” Journal of International Association of P2M, Vol.16, 2021, pp.59-70.
- [14] 経済産業省 高圧ガス保安室, 旭化成(株), 日揮プラントイノベーション(株), アクセンチュア(株), 横河ソリューションサービス(株), 千代田化工建設(株), “IoT 技術を活用した保安高度化の取り組み (後編), 配管技術, vol.86, No.6, 2019, pp.1-6.
- [15] 今村彰太郎, 森永翔, “AI×ドローンによる腐食の自動評価,” 化学工学, Vol.86, No.6, 2022, pp.273-276.
- [16] 石油コンビナート等災害防止 3 章連絡会議 (経済産業省, 厚生労働省, 総務省消防庁), “プラントにおける先進的 AI 事例集～AI プロジェクトの成果実現と課題突破の実践例～,” 2020, <https://www.meti.go.jp/press/2020/11/20201117001/20201117001-4.pdf>, 2023.9.1 参照.
- [17] Chien-Yao Wang, Alexey Bochkovskiy, Hong-Yuan Mark Liao, “YOLOv7: Trainable Bag-of-Freebies Sets New State-of-the-Art for Real-Time Object Detectors,” Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR), 2023, pp. 7464-7475.

## 著者略歴

新保 利弘 (しんぼ としひろ)

1990 年東京理科大学大学院理工学研究科工業化学専攻修士課程修了。同年三菱ガス化学(株)入社。現在, DX

のための AI の活用に従事。専門分野：化学工学，プロジェクトマネジメント。技術士（化学部門，総合技術監理部門）の資格を有す。慶應義塾大学大学院後期博士課程在学中。

**岡田 陽介（おかだ ようすけ）**

㈱ABEJA 代表取締役 CEO 兼創業者。2017 年一般社団法人日本ディープラーニング協会理事。2021 年那須塩原市 DX フェロー。著書に「AI をビジネスに実装する方法」（日本実業出版社）など。共著に「THE 深層学習教科書ディープラーニング G 検定（ジェネラリスト）公式テキスト」（翔泳社），「AI 白書 2022」（KADOKAWA）編集委員。

**藤本 敬介（ふじもと けいすけ）**

2005 年電気通信大学電気通信学部情報工学科卒業。2010 年同大学大学院情報工学専攻博士課程修了。博士（工学）。同年㈱日立製作所入社。基礎研究所，中央研究所を経て㈱ABEJA にて機械学習の研究開発・サービス開発に従事。

**宇野 健人（うの けんと）**

㈱ABEJA プロジェクトマネジャー。合同会社アイアンフォージ代表社員，㈱フリュー社外取締役。

**西村 秀和（にしむら ひでかず）**

1990 年慶應義塾大学大学院理工学研究科機械工学専攻博士後期課程修了。工学博士。2008 年慶應義塾大学大学院システムデザイン・マネジメント研究科教授。専門はモデルベースシステムズエンジニアリング（MBSE），システム安全，制御システム設計。一般社団法人日本機械学会フェロー。

**松原 仁（まつばら ひとし）**

1986 年東京大学大学院工学系研究科情報工学専攻博士課程修了。工学博士。同年通産省工技院電子総合研究所（現産業技術総合研究所）入所，2020 年東京大学次世代知能科学研究センター教授。人工知能学会元会長。