

# 自律移動ロボットと画像異常検知による電力プラント屋内点検の自動化の実証研究

## Empirical Research for Automated Indoor Inspection of Electric Power Plants using Autonomous Robots and Image Anomaly Detection

堀 崎 峻

**要 約** BIPROGY は、2018 年度より電力事業者と共同で、点検の省力化と高度化を目的として、長期的な視野で電力プラント屋内の点検の自動化のための仕組みを開発している。電力プラントの環境とロボットの移動性能、および省力化という目的を踏まえ、安価なロボットを用いて点検エリアの大部分を押さえつつ、中2階エリアや半地下エリアなど安価なロボットでは移動が難しい場所にはドローンを使用するというアプローチを採用している。さらに、多数の点検個所の様々な外観的な異常状態を検知可能とするために、軽量の画像異常検知手法を開発した。2022 年度には、開発したシステムを用いて実地検証を行い、ロボットやドローンについては、移動ルートに配慮することで電力プラントへの適用が見込めるといった結論が得られた。加えて、開発した画像異常検知手法については、検証回数や点検個所種類が少ないため、あくまで参考値となるが、正常状態を正常状態と判定する割合が8割、異常状態を異常状態と判定する割合も8割という結果が得られた。

**Abstract** We have been developing indoor inspection system of electric power plant for labor-saving and enhancement since FY2018 with a power generation company in long term perspective. Based on the environment of a power plant, a mobility of robot, and the purpose of labor-saving inspections, we adopt the method in which an inexpensive robot is used to cover most of the area, while a drone is used to cover areas like mezzanine floor structure and half basement where an inexpensive robot cannot move easily. Furthermore, we developed the lightweight image anomaly detection method for detecting numerous visual anomalies at numerous inspection points. We conducted a demonstration experiment in FY2022 on developed inspection system. As a result, robots and drones can be applied to electric power plants by taking their routes into consideration. And anomaly detection performance of developed image anomaly detection method was 80% for judging normal conditions as normal, and 80% for judging abnormal conditions as abnormal, although these are only reference values due to the small number of verifications and types of inspection points.

### 1. はじめに

経済産業省の産業保安行政において、少子高齢化に伴う産業保安人材の不足や、高度成長期に建設されたプラントの老朽化などの課題への取り組みとして、スマート保安の推進が掲げられている<sup>[1]</sup>。

スマート保安には様々な取り組みがある。その一つに、IoT や AI などの新技術を用いて、人手による作業の効率を改善したり、設備の常時監視により安全性を向上したりすることで、産業保安における生産性の向上と保安力の強化を持続的に推進する取り組みがある<sup>[2][3]</sup>。

BIPROGY 株式会社では、持続可能な産業保安力確保の一環として、2018年度より電力事業者と共同で、ロボットやドローン、AIなどを活用した電力プラント屋内の点検<sup>\*1</sup>の自動化のための仕組みを研究開発している（以降、本プロジェクトと総称する）。2018年度から2021年度までは、電力プラント屋内点検の自動化に資する個別の要素技術を研究し、2021年度にそれらを統合してMVP<sup>\*2</sup>（Minimum Viable Product）を開発した。2022年度には、MVPをさらに発展させ、本格的なサービス提供のためのシステムを開発して、実際に電力プラント屋内において長期間の検証を行い、有用性を評価した。

本稿では、本プロジェクトの自動化に関する課題とそれに対するアプローチ、および、2022年度の実地検証について記載する。2章にて、電力プラント屋内点検の概要と自動化の課題を説明し、それを解決するアプローチとして、3章では点検データの収集手段、4章では開発した画像異常検知手法について述べる。5章にてロボットによる実地検証の内容と結果の概要、6章にてドローンによる実地検証の内容と結果の概要を示す。7章で全体をまとめ、8章で今後の取り組みを記す。

## 2. 電力プラント屋内点検の概要

電力プラントにおける日々の屋内点検を、実地環境と点検内容の二つに分けて整理する。まず、実地環境について記載する。電力プラントは、人手による点検を前提にして各設備が設置されており、人が立ち入れる空間が確保された環境である。ただし、設備の機能や構造の制約から設備同士が密集した狭隘部があり、建屋の構造も半地下エリアや中2階エリアが存在し、いずれも最も狭い箇所は、人ひとり分の空間しか確保されていない。このほか、特徴的な構造物として、油漏れ等の異常の影響を局所化するために、設備周辺に防油堤<sup>\*3</sup>が設置されていたり、分解点検や機器交換を行いやすいように床材に取り外しが容易なグレーチングを用いたりする。これらの環境は、点検データの収集手段に対する要件となる。例えば、点検データ収集手段としてロボットを用いた巡回を想定すると、ロボットのサイズは、人幅程度の狭隘部を通過できる大きさに制限され、さらに、ロボットの移動能力は、半地下エリアや中2階エリアの場所への行き来ができ、グレーチングを走行できるものでなければならない。このほか、防油堤など特徴が平坦な場所でもルートを設定できることという条件がある。これらの要件を踏まえると、物流で使われるAGV<sup>\*4</sup>（Automatic Guided Vehicle）は、サイズが人幅より大きく、タイヤ駆動のため階段の上り下りができず、グレーチングにタイヤが挟まってしまうという理由から、電力プラントにおける点検データ収集手段に採用しづらいことが分かる。

次に、点検内容について記載する。点検の対象設備は多岐にわたり、各設備に異常がないかどうかを、点検員が視覚、聴覚、嗅覚、触覚を使って確認する。例えば、ポンプ一つとっても、電力プラントの運転状態により流量が変わり、計器類の指示値が変動し、発生音も変化する。したがって、どのようなものがどの程度の状態になれば異常と判断するのかについては、その対象や状態が多岐にわたるため、明文化が難しく、点検員の経験やノウハウに依存するところが大きい。このことは、単純なルールベースで異常検知を行うようなアプローチは、いわゆる、知識獲得のボトルネック<sup>[4]</sup>によりうまくいかないことを示唆している。

なお、本プロジェクトでは、視覚、聴覚、嗅覚、触覚を対象とした異常検知技術を研究開発しているが、本稿では、視覚に相当する画像異常検知についてのみ記載する。

### 3. 電力プラント屋内の点検データ収集手段

電力プラント屋内における点検データ収集手段について、映像データの収集を例として、まず、固定カメラの利用を想定した。電力プラント屋内の点検対象設備は無数にある一方で、固定カメラの設置可能台数は設置スペースに限度があるため、すべての点検対象設備を人による点検と同様に上下左右から確認できるように固定カメラを設置することが難しい。したがって、点検対象設備の内、重要度の高い機器に絞って重点的に固定カメラを設置するということが現実的な手段である。短期的な点検自動化の取り組みであれば、この対応でも十分と考えられる。

しかしながら、本プロジェクトは、長期的視野で電力プラント屋内点検の自動化を志向しており、人による点検と同等かそれ以上の高度化を図り、将来的に人の代替を実現することを目指している。この観点を踏まえると、固定カメラの利用は、設置スペースが限られることや、永続的に多数のカメラの維持管理を課されることなど、将来的な解決が見込めない課題が存在する。そのため、本プロジェクトでは、固定カメラを点検データ収集手段から除外した。そのうえで、固定カメラのような課題がなく、さらに、長期的視野で技術発展および収集する点検データの種類の拡張が望めるものとして、点検データ収集手段に自律移動ロボットを採用した。

電力プラント屋内の点検データ収集手段として自律移動ロボットを想定すると、2022年時点では、安価なロボットは足回りがタイヤであることが多く、半地下エリアや中2階エリアに進入できない問題がある。一方で、半地下エリアや中2階エリアに進入可能なロボットというと、階段を上り下り可能な犬型ロボットのような高価なものになる。本プロジェクトの目的の一つが点検の省力化であり、自動化にあたってのコストはできるだけ小さいことが望ましく、高価なロボットを採用しづらい。これらを踏まえて、本プロジェクトでは、2種類のロボットを併用して、それぞれ得意な場所を担当させることで電力プラント屋内における効率的な点検データ収集を試みている。具体的には、人幅サイズの安価な自律移動ロボットを用いて、電力プラント内の大きな領域を占める平坦なエリアをカバーし、それではカバーできない半地下エリアや中2階エリアの点検には、安価な自律移動ドローンを用いる。このほか、グレーチング

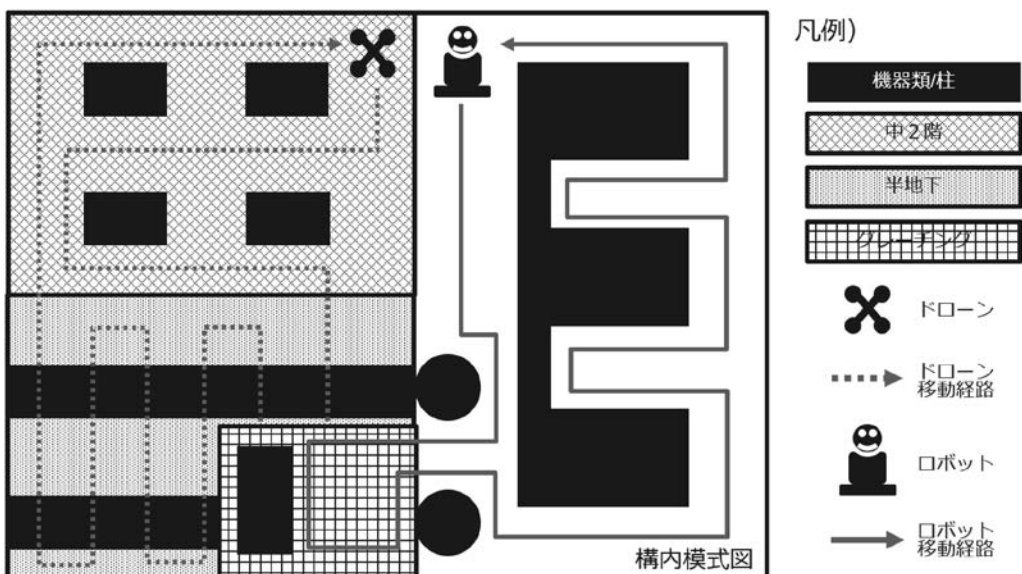


図1 ロボットとドローンを組合わせた点検データ収集手段のイメージ

などの足場の悪い場所については、マットを敷設するなど環境側に手を加えることで、安価な自律移動ロボットによる移動を可能にする。ロボットとドローンを組み合わせた点検データ収集手段の模式図を図1に示す。

#### 4. 開発した画像異常検知手法

電力プラント屋内の視覚による点検を、対象物の種類、観点、個所数の3点から説明する。まず、対象物の種類は、メータ、ポンプ、電動機、調整弁といった具体的なものから、それらを繋ぐ配管のように具体的な名称がなく範囲があいまいなものまで多種多様である。同様に、観点も、メータの指示値確認や、ポンプや電動機における液体漏れ有無、調節弁の開閉状態、周辺に不要なものが放置されていないかなど様々である。さらに、個所数としては、1プラントあたり数百箇所程度が想定されている。

これらの対象物の種類と観点毎に、それぞれに適した異常検知技術を開発する場合、開発コストがかさんでしまう。点検データ収集手段と同様に、コストを最小化するため、本プロジェクトでは、これらのすべての異常状態を共通で検知できる手法を開発する方針とした。

加えて、点検個所数が多いことから、手法開発に当たっては、点検ルールの明文化を伴うルールベースではなく、統計的機械学習の技術をベースとして開発することとした。


このようなアプローチに活用できそうな手法としては、製造ラインを流れる製品の欠陥有無をチェックする外観検査技術が考えられる。このアプローチを本プロジェクトで活用する場合、本プロジェクトでは対象物が様々であること、および、製造ラインのように背景を制限できず、対象物の撮影画像中に不要なものが映りこんでしまうという二つの理由から、点検場所ごとにモデルを構築することになる。

本プロジェクトでは、当初、VAE (Variational Autoencoder)<sup>[5]</sup>を用いたアプローチを試行したが、一つのモデルを作成するために1台のGPUを用いて1日程度の学習時間を要した。仮に1プラントあたり300箇所程度の点検箇所があるとすると、学習だけで300日分の計算量となる。例えば、300箇所分の学習を10日で終わらせるためには、GPUが30台要る。加えて、学習は一度だけではなく、初回学習以後も時々刻々と変化する電力プラント内の状況をモデルに学習させるという再学習も行うため、GPUが運用中に何回も使用され、GPUに係るコストが非常に高くなってしまう。ゆえに、目的とする異常検知をより軽量に実現する手法を開発することとした。

目指す目標値は、300箇所分の学習処理を12時間以内とした。300箇所というのは本プロジェクトにおける電力プラント屋内での点検個所数の試算値である。これに加えて、電力プラント屋内の点検が1日2回程度実施されていることを加味した。この目標値を達成できれば、仮に全点検箇所において、ある点検の時に経時変化による誤検知が検出されたとしても、次の点検までにはモデルの学習処理が完了していることになる。

軽量な画像異常検知手法を開発するにあたり、異常検知の基礎的な考え方であるホテリングの $T^2$ 法<sup>[4]</sup>を出発点とし、VAEを用いた異常検知手法と照らし合わせながら軽量化の検討を進めた。より具体的には、正常データ群 $D$ を用いて正常状態のモデル $p(x|D)$ を求め、そのモデルと推論データ $x'$ を用いて、異常度 $a$ を $a(x') = -\ln p(x'|D)$ として算出するというアプローチである。概要を図2に示す。

■ 学習処理



■ 推論処理




図2 本プロジェクトで開発した画像異常検知手法のコンセプト

結果として、CPU を用いて 100 箇所分の学習処理を数時間程度で処理できる手法を構築できた。3 並列で処理することで目標値を十分クリアできる。参考までに、異常検知例の画像を図 3 に記載する。

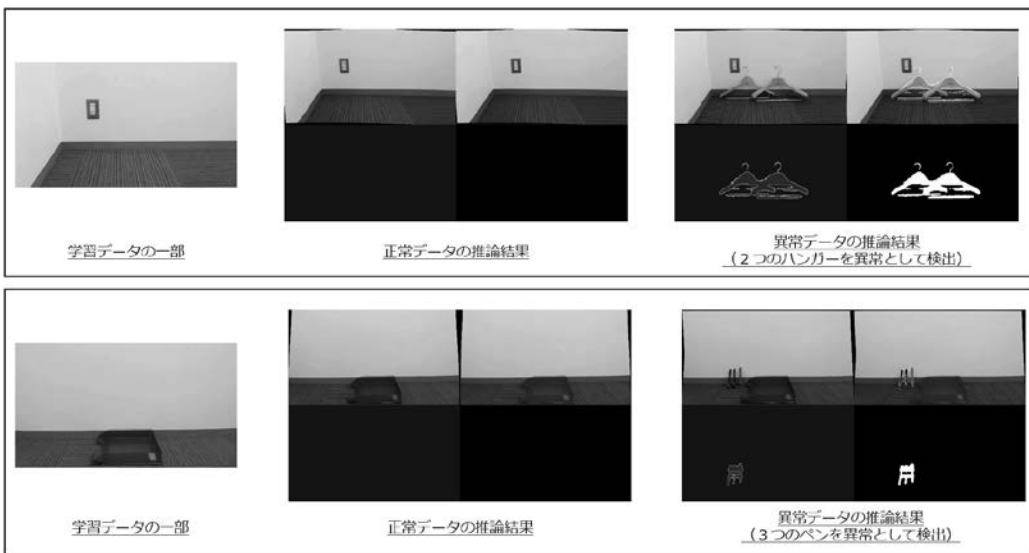


図3 異常検知結果の例 (2箇所)

## 5. ロボットによる実地検証

実環境におけるロボットの自律移動性能と画像異常の検知性能を評価するため、開発したシステムを用いて、実際の電力プラントにおいて長期間の実地検証を行った。本章では、検証内容とその結果の概要を記載する。

### 5.1 検証概要

検証は、本プロジェクトの共同推進事業者が保有する電力プラントのタービン建屋1階で約3か月間にわたって実施した。

点検データ収集手段として、2D-LiDAR<sup>\*5</sup>によるSLAM<sup>\*6</sup>を搭載した安価な人型ロボットを利用した。点検ルートは、検証期間中に順次延伸を行い、検証終了時点では、点検箇所を18箇所含む点検ルートとなった。点検対象は、ポンプやポンプ計、調節弁、温度計、圧力計などである。

画像異常の検知性能の評価にあたり、電力プラントにおいて異常状態が発生することは極めて稀であることに留意すべきであった。そこで、本検証では、異常状態を学習データに含まれていない状態かつ正常状態との差異が明らかなものと定義して、異常検知精度を検証することとした。例えば、メータの指示値が学習データに含まれていないものであれば、実際には異常値ではなくとも異常状態と見做すということである。

### 5.2 ロボットの自律移動性能の検証結果

検証期間中のロボットの自律移動性能については、ロボットの内部処理が原因と疑われる事象を除くと、障害物検知やSLAMによる位置推定に失敗する事象がほとんどを占めた。障害物検知については、電力プラントのタービン建屋内に無塗装の金属製プルボックス<sup>\*7</sup>があり、これが鏡面反射するため、障害物検知センサの測距が正しく行われなかった場合があるというものであった。これに対しては、再帰反射テープをプルボックスに貼り付けることで誤検知を解消することができた。

SLAMによる位置推定に失敗する事象に関しては、明確に周囲の物体配置がルート作成時と変わっている箇所は、ルートを再作成することで対処した。一方で、周囲の物体配置に変化が見られない場所については、2D-LiDARでうまく認識しづらい垂直方向の細い配管などがあることが多く、このような場合は、より特徴的な物体がSLAMのマップに含まれるように移動ルートの修正を行うことで対応することができた。

### 5.3 ロボットによる撮影映像を用いた画像異常検知の検証結果

期間中の全18箇所の点検箇所における合計248回の推論結果を整理すると、ロボットで撮影した映像を用いた画像異常の検知性能については、正常データを正常として判定した割合が約8割、異常データを異常として判定した割合も同じく約8割という結果が得られた。なお、検証したデータ数や点検箇所のバリエーションが少ないため、あくまでこの結果は参考値程度と考えるべきである。

正常データを異常判定してしまうケースは、学習データ不足が原因であることから、再学習で対応することが基本方針となる。一方で、異常データを正常判定してしまうケースは、ロボット移動誤差の影響か点検対象物の画像中のサイズの影響が疑われる。

ロボットの移動誤差の影響をより具体的に説明する。ロボットの移動誤差が大きい場合、撮影画像中の点検対象物の位置がずれる。点検対象物は立体であることから、ずれ方によって見える面と見えない面が生じる。画像を補正して見えない面に見えるようにすることは見えない面の情報がないことから難しい。このため、本プロジェクトで開発したアルゴリズムでは、可能な限り補正をするものの完全に補正しきれない部分は、ずれた状態のまま正常状態として学習するため、正常と認識する状態が広がってしまう。これを防ぐためには、ロボットの移動精度が出やすいようなロボットのルートを選び方やSLAMが認識しやすい特徴的な構造物を付近に設置するなどの工夫を要する。

もう一つの点検対象物の画像中のサイズの影響とは、画像中の対象物のサイズが小さすぎて、検出したい異常の特徴をうまく捉えられないというものである。本プロジェクトで開発したアルゴリズムの最小検知サイズの目安としては、撮影したカメラの焦点距離などに依存するが、100cm先の2cm程度の大きさ、または、50cm先の1cm程度の大きさであれば概ね検知可能であることを確認している。

## 6. ドローンによる実地検証

ロボットによる実地検証と同様に、実環境におけるドローンの自律移動性能と画像異常の検知性能を評価するため、開発したシステムを用いて、実際の電力プラントにおいてドローンを用いた実地検証を行った。本章では、検証内容とその結果の概要を記載する。

### 6.1 検証概要

ロボットによる実地検証と同様に、本プロジェクトの共同推進事業者が保有する電力プラントのタービン建屋で検証を実施した。巡視自動化手段として、ステレオカメラによる Visual SLAM<sup>※</sup>を搭載したドローンを利用した。これは、屋内では、GPSによる飛行ができないためである。点検ルートは、中2階エリアにある点検箇所3箇所を対象としたルートを作成した。このほか、画像異常の検知性能の評価においては、対象設備に対して異常状態を模したテープ等を貼り付けることで異常状態を擬似的に再現した。

### 6.2 ドローンの自律移動性能の検証結果

作成したルートを複数回飛行させた結果、狭隘部の飛行を含めてほぼ100%の精度で自律移動に成功した。自律移動に失敗する例としては、照明条件の変化により、Visual SLAMによる特徴点抽出に失敗して、飛行を継続できないケースなどが確認されている。

なお、ルート作成においては、Visual SLAMで特徴点をうまく捉えられない場所が多く、そのような場所を回避して飛行するためのルート作成に多くの時間を要した。加えて、SLAMのマップ情報の上限ファイルサイズの問題やバッテリー容量に起因した連続飛行可能時間の制約などにも配慮した。

### 6.3 ドローンによる撮影映像を用いた画像異常検知の検証結果

ドローンで撮影した映像を用いた画像異常の検知性能に関しては、点検箇所3箇所について、それぞれ正常データ3本、異常データ2本を推論させたところ、すべてのデータの期待結果と推論結果が一致するという良好な結果が得られた。なお、検証したデータ数や点検箇所のバリ

ーションが少ないため、あくまでこの結果は参考値程度と考えるべきである。

本プロジェクトの画像異常検知手法は、元々、ドローンで使用するために開発していたことや、ドローンでは、Visual SLAM という視覚情報を用いて位置調整を行う技術を使用しているため、2D-LiDAR のロボットよりも、撮影毎の映像の誤差が小さいことが奏功しているものと考えられる。

## 7. まとめ

本稿では、電力プラント屋内の点検自動化による点検の省力化および高度化という目的の下、電力プラント屋内点検を、実地環境と点検内容に分け、それぞれに対して具体的な手段を検討し、実際に実地検証を行った結果を記載した。

実地環境とそれに対する点検データ収集手段については、電力プラントの特徴を踏まえたロボットの選定基準として、人幅程度の狭隘部を通過できるサイズであることや、半地下エリアや中2階エリアへ行き来できること、グレーチングを走行できることなどを挙げ、それに対する安価な実現方法として、2種類のロボットを併用して、それぞれ得意な場所を担当させることとした。

点検内容とそれに対する異常検知手段については、点検員の経験やノウハウに依存するところが大きく点検内容や観点を明文化することが難しいことや、点検対象物の種類と数が膨大であることから、点検対象物の種類に依らず、かつ、点検箇所毎に正常状態を学習しても計算量が少なく済む手法が求められたことを踏まえて、異常検知の基礎的な考え方であるホテリングの  $T^2$  法を出発点として本プロジェクト独自の手法を開発した。

さらに、2D-LiDAR のロボットと Visual SLAM のドローンのそれぞれについて個別に実地検証を行い、どちらも留意事項はあるものの適切な工夫を行えば、電力プラントへの適用が見込めることを示した。

加えて、本プロジェクトで開発した画像異常検知手法については、実地検証したデータ数や点検個所のバリエーションが少ないため、あくまで参考値となるが、2D-LiDAR のロボットの場合、正常データを正常として判定する割合が約8割、異常データを異常として判定する割合も同じく約8割という結果が得られた。ドローンについてはさらに良好で、3箇所の各5回分の推論について期待通りの結果が得られた。

## 8. 今後の取り組み

今後の取り組みとして、点検データ収集手段と画像異常検知それぞれについて述べる。まず、点検データ収集手段として今回はSLAMを用いたものを採用したが、電力プラント内では時折、作業が行われており、資機材等の配置が時々刻々と変化するため、マップの情報が徐々にルート作成時とずれていく。長期間運用した場合、このずれの蓄積が原因で、自律移動に失敗するケースが見られる。これを回避するために、定期的にルートを再作成するという手間がかかる。点検の省力化という本来の目的を考えると、この手間が不要であることが望ましい。言い換えると、よりロボスタ性の高い技術を検討するべきである。例えば、ライントレースのようにラインさえ維持されていれば、問題なく移動が可能な方式や、3D-LiDAR のように2D-LiDAR よりもより多くの情報を取得できる方式などが検討に値すると考えられる。

なお、ドローンについては、より実用性を高めるために、SLAM マップのファイルサイズ



上限に起因する連続飛行可能距離やバッテリー容量に起因する連続飛行可能時間の改善が望まれ、今後の発展を期待する。

次に、画像異常検知について述べる。本プロジェクトで開発した手法は、軽量であることを重視したため、深層学習のアプローチを採用しなかった。しかしながら、より実用的な異常検知性能を得るためには、深層学習のアプローチを視野に入れることが望ましい。なお、本プロジェクトのように場所ごとにモデルを学習する場合に深層学習を採用すると、膨大な計算量となることが懸念されるが、例えば、ResNet<sup>[6]</sup>を用いて特徴量を抽出して異常検知する手法<sup>[7][8]</sup>など、深層学習部分の学習処理を行わない手法と同様のアプローチを採用することで問題を軽減できる可能性がある。今後は、これらの手法を参考にして更なる異常検知性能の向上を検討していきたい。

## 9. おわりに

本稿を執筆するにあたりアドバイスを下さった方々、実地検証にご協力いただきました本プロジェクトの共同推進事業者様をはじめとしたプロジェクトメンバの方々に感謝の意を表する。

- 
- \* 1 電力プラントでは、電気事業法に定められた分解点検等に加えて、毎日、巡視点検が行われている。この巡視点検は、屋内設備と屋外設備の両方が対象である。本稿ではこれらの点検の内、屋内の点検のみを取り扱う。
  - \* 2 サービス利用者に価値を提供できる最小限の製品のこと。
  - \* 3 油漏れ発生時の影響範囲を局所化するために、電動機やポンプの周囲に設置されるコンクリート製の囲いのこと。
  - \* 4 倉庫などにおける人の搬送作業を代替する無人搬送車のこと。
  - \* 5 ロボットから水平方向にレーザー光を照射して反射光を計測することでロボットの周辺の物体までの距離を計測する技術。
  - \* 6 Simultaneous Localization and Mapping の略。ロボットの自己位置の推定と周辺環境の把握を同時に行う技術のこと。
  - \* 7 電線などのケーブルの分岐部分に設置される箱のこと。
  - \* 8 SLAMのうち、周辺環境の把握にカメラを用いる技術のこと。

- 参考文献**
- [1] 今後の産業保安行政のあり方について，経済産業省産業保安グループ，2020年6月4日，[https://www.meti.go.jp/shingikai/sankoshin/hoan\\_shohi/pdf/004\\_03\\_01.pdf](https://www.meti.go.jp/shingikai/sankoshin/hoan_shohi/pdf/004_03_01.pdf)
  - [2] スマート保安推進のための基本方針，スマート保安官民協議会，経済産業省，2020年6月29日，[https://www.meti.go.jp/shingikai/safety\\_security/smart\\_hoan/pdf/kihon\\_hoshin.pdf](https://www.meti.go.jp/shingikai/safety_security/smart_hoan/pdf/kihon_hoshin.pdf)
  - [3] 電気保安分野スマート保安アクションプラン，スマート保安官民協議会 電力安全部会，経済産業省，2021年4月，[https://www.meti.go.jp/shingikai/safety\\_security/smart\\_hoan/denryoku\\_anzen/pdf/20210430\\_2.pdf](https://www.meti.go.jp/shingikai/safety_security/smart_hoan/denryoku_anzen/pdf/20210430_2.pdf)
  - [4] 井出剛，杉山将，「機械学習プロフェッショナルシリーズ 異常検知と変化検知」，講談社，2015年8月，P1～P25
  - [5] Diederik P Kingma, Max Welling, “Auto-Encoding Variational Bayes”, Machine Learning Group Universiteit van Amsterdam, 2014.05
  - [6] Kaiming He, Xiangyu Zhang, Shaoqing Ren, Jian Sun, “Deep Residual Learning for Image Recognition”, Microsoft Research, 2015.12
  - [7] Thomas Defard, Aleksandr Setkov, Angélique Loesch, Romaric Audigier, “PaDiM: a Patch Distribution Modeling Framework for Anomaly Detection and Localization”, Université Paris-Saclay, 2020.11
  - [8] Karsten Roth, Latha Pemula, Joaquin Zepeda, Bernhard Scholkopf, Thomas Brox, Peter Gehler, “Towards Total Recall in Industrial Anomaly Detection”, University of Tubingen, Amazon AWS, 2022.05

※ 上記参考文献内の URL のリンク先は、2023 年 8 月 3 日時点での存在を確認。

**執筆者紹介** 堀 崎 峻 (Shun Horizaki)

2011 年日本ユニシス(株)入社。(現：BIPROGY)。2016 年より新規事業のための PoC や実証実験を担当。2019 年より自律移動ロボットと異常検知技術を用いたプラント屋内点検の省力化・高度化のプロジェクトに参画。機械学習アルゴリズムの開発チームリーダー、および、点検システムのアーキテクト、テクニカルリーダーを務める。

