

【研究論文】

【令和3～4年度 地域企業競争力強化支援事業】

## 環境発電、多点センシング、ビッグデータ処理を活用した県内産業の高度化

小野 仁、中居 倫夫、今井 和彦、太田 晋一、荒木 武<sup>\*1</sup>、高野 寛己、林 正博<sup>\*2</sup>  
 機械電子情報技術部（<sup>\*1</sup>現 自動車産業支援部 <sup>\*2</sup>現 材料開発・分析技術部）

多数のセンサを異なる場所に配置しデータを収集する多点センシングは、IoTの重要な要素である。また、多点センシングを行う無線センサの電源として、環境発電の応用が期待されている。一方で、多点センシングにより得られるデータは、膨大な量となり、画像処理等において使用されるビッグデータ処理技術の活用が必要となる。そこで本研究では、多数接続可能、カスタマイズ可能な自立電源の多点無線センサシステムを開発し、地域企業等へ技術移転するとともに、ビッグデータ処理の中でも特に重要な画像処理AI技術を、地域企業が導入しやすい形で技術移転することを目標とした。結果として、自立電源化可能な省電力の多点無線センサシステムを開発し、室内温度の測定、工程見える化への応用、地震検知及び獣検知への応用を試み、有効であることを確認した。また、無線センサへの環境発電の活用を試みた。さらに、画像処理AIについては異常検知AI、アノテーションツール、説明可能AIについて調査を行ったので報告する。

キーワード: IoT、AI、多点センシング、無線センサ、ビッグデータ、自立電源、環境発電、画像処理、異常検知AI、アノテーション、説明可能AI

### 1 緒言

多数のセンサを異なる場所に配置し、データを収集する多点センシングは、IoTの重要な要素だが、地域企業が独自に様々な部品を選択編成し、動作するシステムにまで持って行くことは困難である。また、多点センシングを行う無線センサの電源として環境発電の応用が期待されているが、地域の環境発電デバイス関連企業が単独でIoTシステムを構築することは困難である。

一方で、多点センシング等により得られるデータは膨大な量となり、画像処理等において使用されるビッグデータ処理技術の活用が必要となるが、地域企業が単独で当該技術を導入することは困難である。

そこで、本研究では、多数接続可能、カスタマイズ可能な自立電源の無線多点センサシステムを開発し、地域企業等へ技術移転するとともに、ビッグデータ処理の中でも特に重要な画像処理AI技術を、地域企業が導入しやすい形で技術移転することを目標とした。

なお、本研究は、無線多点センサシステムを開発し、その応用展開を検討する部分と、画像処理AIについて調査する部分に分かれるので、それぞれについて節を分けて説明する。

### 2 多点無線センサシステムの開発と応用

無線センサは有線センサと比較して、信号線が必要ないことから、簡単に多数設置できて、設置場所の制約も少ないという優位性があり、これはセンサの数が多いほど顕著になる。また、この優位性は、電力供給のための線が必要ない(自立電源化している)場合、さらに顕著になる。そこで多点無線センサシステムを開発し、さらに多点センシングならではの応用展開を試みるとともに、環境発電の活用を試みた。

#### 2.1 多点無線センサシステムの開発

多点無線センサシステムは、図1に示すように多数の無線センサ、1台の受信機、データ表示・保管用のパソコンから構成される。

無線センサには、先の研究により開発した小電力無線センサキット<sup>1)</sup>を用いた。小電力無線センサキットは、安価な市販の部品で構成され、コイン電池(CR2032)で1年以上動作可能で、コイン電池を環境発電に置き換えることも容易である。

無線データは、約100バイト / パケットで1分ごとに送信され、受信側は79台までの無線センサからの受信データを1台の受信機により受信し、事務処理で使われる程度のスペックのノートパソコンにデータを保存しつ

つ、画面上にリアルタイムにグラフを表示可能であることを確認した。

ソフトウェアは、データ受信部分にはPython、グラフ表示部分にはJavascriptを用いて構築したが、Node-RED等のノーコード開発ツールで置き換えることも可能である。

また、本システムで1分ごとに1年間データを蓄積した場合のデータ量は、無線センサ1台当たり87 Mバイトであり、79台まとめると6.9 Gバイトになることを確認した。




図1 多点無線センサシステム

## 2.2 多点無線センサシステムの応用展開

開発した多点無線センサシステムを用いて、多点センシングのメリットを生かした応用展開を4種類試みた。

具体的には、県内企業と共同して、多点センシングによる室内温度測定及び製造工程の見える化を試みた。また、地震検知と獣検知への応用を試みた。

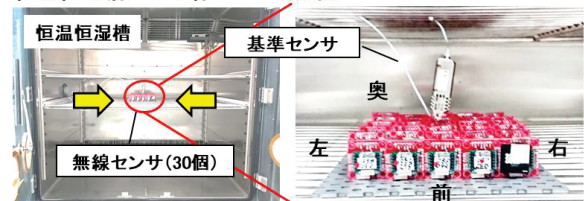
### 2.2.1 室内温度測定への応用

金型部品や装置部品には $\mu\text{m}$ 単位の加工精度を求められる場合があるが、金属の熱膨張係数は、一般に $10\mu\text{m}/\text{K}$ (1 m当たり)以上であるため、精密加工を行う工場においては、精密な室温管理が要求される。一方で空調の数は限られるため、場所による室温の違いが発生することは避けられない。そこで、多数のセンサを用意し、それぞれを加工機の近くに置くことにより、より精密な室温管理が可能となる。

プラスエンジニアリング(株)では、仙台事業所の微細加工棟において、装置ごとに最大30か所において $23 \pm 0.5 \text{ }^\circ\text{C}$ で温度管理したいというニーズがあり、開発した多点無線センサの温度センサ(ADT7410)が適用できると思われたが、全ての無線センサがシステムとして精度を長期間保てるかどうか確認する必要があった。

そこで当センターでは30個の無線センサの温度測定精度とその経時変化を1年半にわたり追跡した。具体的には、微細加工棟に設置した無線センサを定期的に回収し、気温 $23 \text{ }^\circ\text{C}$ での気温測定精度を、当センターの恒温恒湿槽により確認した。恒温恒湿槽は槽内の位置による温度分布を持つことからこの点に留意し、図2に示すように大型の超低温恒温恒湿槽(PSL-4KPH)を用い、無線センサを槽の中央部に置くことにより30個全ての温度センサをほぼ同じ温度条件になるようにした。また、温度精度 $\pm 0.1 \text{ }^\circ\text{C}$ の基準センサを無線センサ近傍に配置して、槽内温度を $23 \text{ }^\circ\text{C}$ に設定し、安定後1分おきに60回測定し平均値を求めた。

恒温恒湿槽内の無線センサの配置



槽の大きさとして無線センサの位置による温度測定結果の違い




図2 多点無線センサシステムの温度精度評価方法

温度測定値の長期間の経時変化を図3に示す。基準センサの温度が測定の度に $1 \text{ }^\circ\text{C}$ 以下の範囲で変動しているのは恒温恒湿槽の温度制御の限界を示す。この条件で30個の無線センサの温度測定値は、基準センサ $\pm 0.3 \text{ }^\circ\text{C}$ 以内に収まっており、無線センサの劣化や電池の消耗等の影響なく、開発した多点無線センサシステムにより長期的に $23 \pm 0.5 \text{ }^\circ\text{C}$ 程度での温度管理が可能であることが確認できた。




図 3 無線センサ30 個の温度測定値の経時変化

2.2.2 工程見える化への応用

工場に新規導入される機器の多くは、既にIoTが内包されているが、過去に導入した機器を用いてIoTを実施しようとする、電源線や通信線を這わせるスペースが無い場合、多点無線センサが有効である。

東北特殊鋼(株)では、工場内に数 m～数10 m間隔で数10 台ある熱処理炉の稼働状況を一箇所から監視するために、熱処理炉のシグナルタワーのモニタリング用に当センターがカスタマイズした無線センサ<sup>1)</sup>を10 個熱処理炉ごとに設置し、図4に示すようにパソコン上の集中管理画面を社内内で内製して、熱処理工程の見える化を試行した。数週間の試行の結果として、当該システムが機能することが確かめられた。




図 4 集中管理画面の例(東北特殊鋼作成)

2.2.3 地震検知への応用

多点センシングにより、事象の原因の特定が容易になる。例えば、地理的に異なる複数の加速度センサが同

時に振動を検知した場合、地震が原因であると判断できる。

宮城県北部地方振興事務所では、管内66 か所存在する防災重点ため池の内、ダム(高さ15 m以上)として管理しているため池において、地震の加速度を測定するニーズがあったので、加美町にある孫沢ため池において、多点無線センサシステムを用いた評価を実施した<sup>2)</sup>。

図5に示すように加速度センサ(ADXL345)を堤体上部の操作室内に1 個、操作室から約40 m離れた堤体下部の放流管出口に2 個設置し、操作室内に設置した記録装置に、加速度振幅を1 分間隔で送信した。

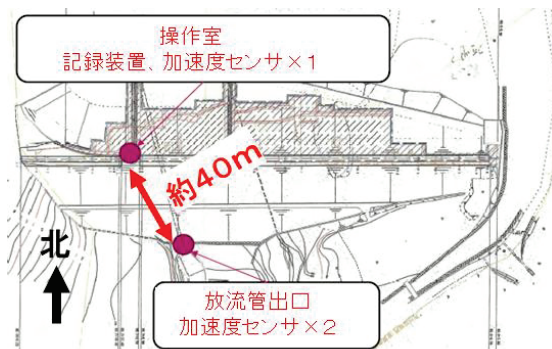


図 5 孫沢ため池における設置状況



図 6 孫沢ため池における震度 5 強の地震検知結果

本システムを検証した結果、図6に示すように、2022年3月16日に加美町で震度5強の地震が観測された際、全てのセンサが加速度を検出し、地震が検知可能であることが確認された。また、操作室内で振動が検知されない状況で、放流管出口でのみ加速度振幅が0.5 Gに達する大きな振動が検出されたので調査したところ、水流により放流管が大きく振動するところを発見できた。しかし本手法を適用するには、複数の震度での測定や、地震検知用に一般的に使用される加速度センサとの比較といった、測定法としての検証や、測定したデータの低コストでの遠隔送信等、様々な課題があることも明らかになった。

本実験において、孫沢ため池での無線センサや記録装置の設置・回収、データの収集、解釈等においては、北部地方振興事務所農業農村整備部農村振興班技術

次長(班長)の小泉慶雄氏に多大な支援を頂きました。深く感謝いたします。

### 2.2.4 獣検知への応用

多点センシングにより、1点では不確実な情報の確実性を向上できる。例えば、焦電型赤外線センサ(PIRセンサ、人感センサ)は、温血動物(獣)が発する遠赤外線と周囲の温度差の時間変化を捉えるセンサで、安価で省電力だが、これを屋外に置いて獣検知センサとして使用しようとする、誤検知が問題となる。この誤検知を多点センシングにより解決することを試みた。

図7に示すように、1つの獣検知ノードには2つのPIRセンサを各々反対方向に取り付け、当センターの敷地において、猪の通り道を横切る形で、PIRセンサの検知限界(5m)以内の4~5mおきに4個の獣検知ノードを設置した。この設置方法により、獣が設置場所を通った際、2つのセンサが反応するため、誤検知を削除することが可能になる。

2022年の夏から秋にかけて試行した結果、3回発生した猪被害の際には、いずれも1時間程度の間にも多数のPIRセンサが反応しており、夜間という限られた条件ではあるが、獣検知の手法として有効であることが確認できた。

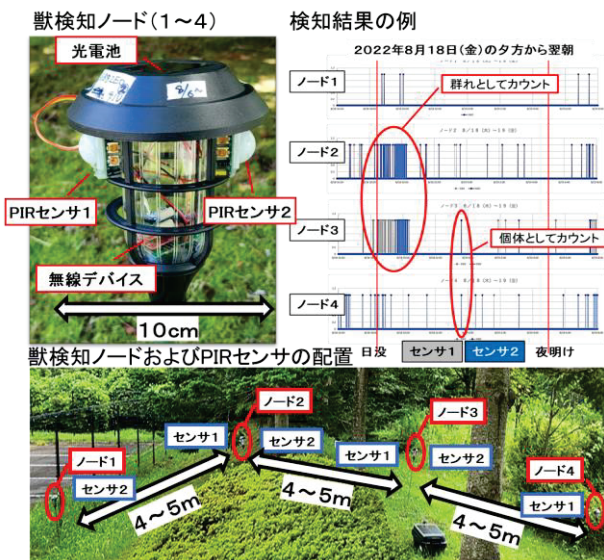


図7 獣検知ノードと検知結果の例

### 2.3 無線センサへの環境発電の活用

多点センシングにおいて、無線センサは、数を増やしたり様々な場所に置くほど電池交換のコストが上昇するため、環境発電を活用した自立電源化が必要になる。

そこで本研究では、まず小電力無線センサキットによる簡易的な環境発電の活用を試みた後、回路設計をやり直し、環境発電体と一体化した無線センサの開発を試みた。なお、これらの開発において、環境発電により得られた電力を蓄積するため、先の研究開発の成果<sup>3)</sup>である蓄電回路<sup>4)</sup>を活用した。

#### 2.3.1 小電力無線センサキットによる環境発電の活用

2.2.1で使用した30個の無線センサは、1分間に1回の無線送信を行うように設定した場合の消費電力が約50  $\mu$ Wであり、10  $\text{cm}^2$ の光電池(AM-1417CA $\times$ 2枚)で電力供給が可能である。そこで図8に示すように一部(10台)の無線センサの電源を環境発電に置き換えることを試行した。置き換えの方法は、小電力無線センサキットの電源ボードを環境発電用ボードに交換し、上部に光電池を乗せる簡易的な方法とした。なお、全体の重量は33gとなった。この無線センサは200 lx以上の室内光から連続動作するため、人が常に作業している環境であれば使用可能である。




図8 省電力無線センサキットによる環境発電の活用

#### 2.3.2 環境発電体と一体化した無線センサの開発

小電力無線センサキットは、汎用性を重視しているため、コンパクト性や軽量性の面では劣る。そこで環境発電も含めた全ての機能を1枚の基板上にまとめた一体化デバイスの開発を試みた。

結果として、図9に示すように、小電力無線センサキットを用いた無線センサの2倍の面積(21  $\text{cm}^2$ )の太陽電池を持ちながら、重量が1/3(11g)、かつ厚みが薄い(3mm)自立電源無線センサを開発した。この無線センサは、軽く薄いため、様々な方法で取り付けが可能で、また20 lx以上の室内光により動作開始するため、薄暗い室内の物陰のようなところでも、数10分~数時間ごとに1回動作可能である。




図 9 環境発電体と一体化した無線センサ

## 2.4 まとめ

79 台までの無線センサを1 台の受信機で処理する多点無線センサシステムを開発し、県内企業2 社へ技術移転した。また多点センシングならではの応用展開を4 件試行し、有効性を確認した。さらに、多点無線センサの電源を環境発電で置き換えることにも成功した。

これらの成果により、多点センシングと環境発電の両方の可能性を示すことができた。無線による多点センシングはセンサの数が増えるほど環境発電による自立電源化の必要性が高まるため、これらの成果は、地域企業の競争力強化のために有効である。

## 3 中小企業が導入しやすい画像処理 AI 技術の調査

### 3.1 はじめに

近年、製造現場の外観検査において、画像処理 AI の導入が盛んになっている。しかし、AI 導入の現場でのハードルがいくつか報告されており、その中でも特に課題となっているのは、①収集した学習データの正常品が多く異常品が極めて少ないこと、②AI の教師データ作成(アノテーション)に時間がかかること、③AI の判断根拠が不明瞭であることである。これらの問題を解決するためには、正常品が多く異常品が極めて少ないデータに対応するアルゴリズム(異常検知 AI)の導入が必要となる。またアノテーション効率化においては、高機能なアノテーションツールの導入が求められる。さらに、AI の判断根拠を明確化するためには、AI の判断理由を可視化する手法の導入も必要である。本研究では、これらの問題について調査し、解決策を提案することを目的とした実験及び調査を行った。

### 3.2 異常検知 AI

深層学習を用いた画像処理 AI の代表的技術として、画像分類、物体検出、領域分割(セグメンテーション)が挙げられるが、3 手法は全て学習データにおいて各カテゴリごとに十分枚数が必要なものである。特に画像分類では、カテゴリごとに同数の画像枚数が必要となるため、正常品が多く異常品が少ないカテゴリごとに画像枚数が不均衡な場合に適用することが困難である。そこで、こうしたデータセットでも、ある程度の判別性能が期待される異常検知 AI(良品学習)に着目し、実際の導入に向け調査を行った。

#### 3.2.1 オートエンコーダ(AE)の仕組み

異常検知 AI で有名なアルゴリズムとして、オートエンコーダ(Auto Encoder: AE)がある。AE は、入力データを潜在変数に変換し、再び出力データに復元するニューラルネットワークである。AE は、訓練中に入力データを表現する特徴を学習し、その表現を使用してデータを再構成することができるようになる。そして、入力データと再構成されたデータとの間の再構成誤差を最小化するように訓練が行われる。異常検知においては、正常なデータで訓練した AE に、異常なデータを入力することで、再構成誤差が大きくなることが想定される。この仕組みを利用し、再構成誤差の閾値を設定することで、入力画像の異常を検知することができる。(図 10 参照)




図 10 AE の構造: 入出力の差分により正常と異常の判定を行う。

#### 3.2.2 AE を用いた実験

3.2.1 に紹介した AE をオープンソースの PyTorch を用いて構築した。エンコーダ部 6 層、デコーダ部 6 層から成り、入出力の差分で閾値を設定することで正常異常の判定を行う。

実装は機械学習のフレームワークの一つである PyTorch を導入し、python3.7 を用いて開発した。開発環境として Anaconda3 を用いた。ハードウェアのスペック

クは以下のとおりである。

- CPU: Intel Core i7-9700K CPU
- RAMメモリ: 48 GB
- GPU: NVIDIA GeForce GTX1080Ti

工業製品のサンプルとしてオープンデータセットの一つであるMVTecAD<sup>5)</sup>と呼ばれる工業製品の画像検査向けに作成された画像データセットを用いた実験を行った。15 カテゴリの工業製品から成り、それぞれに正常画像と複数種の異常画像、欠陥領域を図示したアノテーション画像が含まれている。本研究では、MVTecAD のうち工業製品に関連のある物体クラスの Bottle 及び Transistor の画像データを用いて実験を行った。訓練画像は、Bottle に関して正常画像のみ 166 枚、Transistor に関して正常画像のみ 170 枚で学習を行った。評価画像について、Bottle の正常画像 63 枚、異常画像 20 枚、Transistor の正常画像 103 枚、異常画像 30 枚について評価を行った。

### 3.2.3 実験結果

受信者操作特性曲線(ROC 曲線)の AUC 値を性能指標として評価を行った。これは、ROC 曲線の下部分の面積を示す指標であり、0 から 1 までの値をとる。ROC 曲線は、真陽性率(TPR)と偽陽性率(FPR)をプロットしたものであり、AUC 値が 1.0 に近いほど、クラス分類器の性能が高く、完全に陽性クラスと陰性クラスを分離できることを示している。一方、AUC 値が 0.5 に近いほど、クラス分類器の性能が低く、AUC 値=0.5 がランダムに分類することと同義である。

Bottle と Transistor について、AUC 値はそれぞれ図 11、図 12 のとおり 0.97、0.74 であり、特に Bottle においては高い性能を示した。Transistor についても良好な性能であることが分かった。また、Bottle、Transistor について評価画像例を図 13、図 14 に示す。元の画像と再構成画像の差分が大きいかほど差分画像の異常領域付近が赤色で表されており、差分画像の異常度で閾値を適切に設定することで、入力画像の正否判定が可能となる。




図 11 Bottle の ROC 曲線 (AUC 値: 0.97)




図 12 Transistor の ROC 曲線 (AUC 値: 0.74)




図 13 Bottle の評価例:元の画像(異常画像)と再構成画像の差分を表示しており赤色に近いほど差分が大きいことを示す。




図 14 Transistor の評価例:元の画像(異常画像)と再構成画像の差分を表示しており赤色に近いほど差分が大きいことを示す。

### 3.3 アノテーションとは

画像処理 AI におけるアノテーションとは、機械学習・深層学習モデルの学習に必要な正解データを人手で付与することを指す。アノテーションの難易度・煩雑性は、画像分類、物体検出、セグメンテーションの順で増すものである。画像分類では、画像に対して正解クラスを割り当てるだけであり、比較的簡単なアノテーション作業で済む。ただし、分類するクラス数が多い場合、または似たような画像が多く含まれる場合には、正解クラスの付与が複雑となり学習が難しくなる。物体検出では、画像内に存在するオブジェクトの位置とその種類を特定するため、画像分類に比べてアノテーション作業の煩雑性が増す。さらに複数のオブジェクトが存在する場合には、それぞれのオブジェクトの位置と種類を正確にアノテーションする必要がある。また、オブジェクトが重なり合っている場合や、一部が隠れている場合には、より複雑かつ緻密なアノテーション作業が必要となる。セグメンテーションでは、画像内の各ピクセルに対して正解クラスを割り当てる必要がある。物体検出に比べてさらに煩雑性が増し、オブジェクトの境界が曖昧な場合には、人手で正確なアノテーションを行うことが困難となる。

アノテーションには、正確で信頼性が高く、一貫性が必要となる。また、作業には時間と費用がかかるため、GUI に優れ高機能なアノテーションツールを活用することが不可欠となる。本項では、こうした煩雑なアノテーションについて、無償で行える比較的高機能なツールから有償のツールを調査し、アノテーションの煩雑性の軽減につながる検討を行った。

#### 3.3.1 無償アノテーションツールの例

##### (1) labelImg

labelImg<sup>6)</sup> は、物体検出 AI のためのアノテーションツールとして活用でき、開発者が無料で提供しているオープンソースソフトウェアである。ユーザーは、画像上のオブジェクトを長方形(矩形)でラベル付けし、物体検出タスクに必要なオブジェクトの位置と種類を示すアノテーションデータを作成することができる。アノテーションファイルは xml ファイル形式で出力される。また画像のプレビュー機能や、ラベルと画像の保存機能も備えており、データセットを効率的に作成できるツールである。物体検出は、画像分類に比べ、アノテーションの難易度・煩雑性が高く、正確なアノテ

ーションデータの作成が求められるため、labelImg のような高機能なアノテーションツールの活用により作業効率の向上が見込まれる。

導入は、OS:Windows10 に Anaconda パッケージをインストールし、

1. activate (python の仮想環境名)
2. cd (labelImg.py があるディレクトリ)
3. pyrcc5 -o resources.py resources.qrc
4. python labelImg.py

と入力することで起動される。

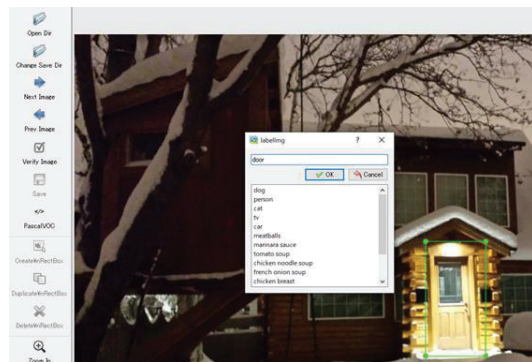


図 15 labelImg での作業画面：物体を囲むことで画像上の物体の位置が xml ファイルで出力される。

##### (2) labelme

labelme<sup>7)</sup> も(1) labelImg と同様に、画像アノテーション用のオープンソースツールであり、Python のライブラリとして提供されている。labelme では、画像に対して矩形選択に加えて、ポリゴン、点などの形状でアノテートすることが可能である。アノテーションファイルは JSON ファイル形式で保存され、編集や再利用が可能である。また、ラベルの色や名前、線の太さなど、比較的効率よくアノテーションができる。labelme は、物体検出・セグメンテーションのデータセットを作成するために広く使用でき、高度なカスタマイズや、様々な画像形式のサポートなど、多様な機能を備えている。

導入は、OS:Windows10 に Anaconda パッケージをインストールし、

1. activate (python の仮想環境名)
2. cd (labelme.py があるディレクトリ)
3. pip install labelme
4. labelme

と入力することで起動される。

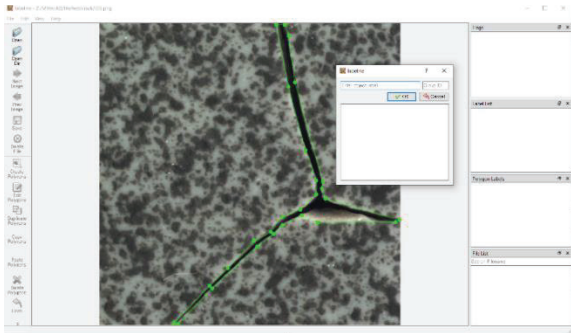


図 16 labelme での作業画面：検出したい部位を多角形で囲み、画像上の座標が JSON ファイルで出力される。

### (3) CVAT

CVAT (Computer Vision Annotation Tool)<sup>8)</sup>は、Intel 製のオープンソースのデータアノテーションツールであり、画像や動画などのデータを効率的にアノテーションすることができる。CVAT では、複数のアノテーターが同時に作業することができ、アノテーションの進捗状況を確認することもできる。画像分類、物体検出、セグメンテーション用のデータセット作成が可能で、GUI も優れて使いやすいソフトウェアである。

導入は OS: Windows10 に Anaconda パッケージをインストールし、以下を実行する。

1. WSL2 (Windows subsystem for Linux)を導入
2. Docker Desktop for Windows を導入
3. Git for Windows を導入
4. Chrome をインストール
5. GitBash で以下コマンドを実行
6. Chrome の URL 欄に `http://localhost:8080/` と入力

高機能なアノテーションツールであるが、導入がやや難しい。



図 17 CVAT での作業画面：検出したい部位を多角形で囲み、画像上の座標が JSON ファイル等様々な形式で出力される。

### 3.3.2 有償アノテーションツール例

3.3.1 で紹介したアノテーションツールは、無償ながらも GUI に優れ比較的高機能なものであった。一方で、無償のツールのほとんどは、線傷のような細長い形状の物体についてを画像上から選択するには、それらを多角形で囲む必要があり、煩雑で正確な処理が必要となる。これはアノテーション作業を困難にし、時間とコストがかかる可能性がある。有償 AI ツールは、自動車や飛行機のような製品の線傷検査において、細長い線状の傷をマスクすることができ、画像の処理を簡単にできる。

画像処理ソフトウェアの Aurora Vision (旧 Adaptive Vision) における線傷のアノテーションでは、図 18 の作業をマウスクリックで塗り絵のように指定できる。他の画像処理 AI ツールの多くはセグメンテーション機能において、欠陥部位を多角形で囲むのではなくマウス操作で塗り絵のように指定することができる。これにより、線傷のような細長い欠陥及び複雑形状の欠陥を指定することが容易となる。




図 18 Aurora Vision におけるアノテーション作業の様子

### 3.4 説明可能 AI

深層学習の中身は、ブラックボックスと呼ばれることが多く、出力や予測結果の判断根拠を示す技術(説明可能な AI: explainable AI: xAI) について検討が進んでいる。この課題を解決すべく様々な技術が提案されている<sup>9)</sup>。

画像処理ソフトウェア Aurora Vision では、判断根拠を可視化する機能が備わっており、それらを用いることで異常検知 AI 及び画像処理において判断根拠の可視化が可能となる。本項では説明可能 AI に関する実験を行い、その有効性を調査した。



## 3.4.1 異常検知 AI (Detect Anomalies) の説明可能性

異常検知は前項で述べたとおり、データセットにおける異常画像が少ない場合においても、ある程度有効な AI 手法である。実験では MVtecAD の Tile について正常画像 60 枚、異常画像 8 枚で学習を行った。評価データの異常画像について、異常箇所注目領域が確認され AI が正しく欠陥位置を特定し判別を行っていることが分かった。(図 19 及び図 20 の右: 赤色領域)




図 19 異常検知 AI の注視領域(1)  
(左) 元画像 (右) AI 判断根拠画像




図 20 異常検知 AI の注視領域(2)  
(左) 元画像 (右) AI 判断根拠画像

## 3.4.2 画像分類 AI (Classify Object) の説明可能性

画像分類の実験では MVtecAD の Toothbrush について正常画像 30 枚、異常画像 27 枚で学習を行った。画像分類 AI においても評価データの異常画像について、異常箇所注目領域が確認され AI が正しく欠陥位置を特定し判別を行っていることが分かった。(図 21 及び図 22 の右: 赤色領域)




図 21 画像分類 AI の注視領域(1)  
(左) 元画像 (右) AI 判断根拠画像




図 22 画像分類 AI の注視領域(2)  
(左) 元画像 (右) AI 判断根拠画像

## 3.5 まとめ

地域企業が製造現場などにおいて AI 導入の課題となりうる、正常品が多く異常品が少ないというデータ不均衡に対する課題、アノテーション作業の煩雑さ、AI の説明可能性について調査・実験を行った。AI のタスクに合わせたアノテーションツールの展開や xAI を活用した企業支援にも繋がっている。

今後は特に製造現場での課題である異常データの収集が困難であり、学習データが不均衡となる課題について重点的に取り組む予定である。

## 4 結言

79 台までの無線センサを1台の受信機で処理する多点無線センサシステムを開発し、県内企業2 社へ技術移転した。また多点センシングならではの応用展開を4 件試行し、有効性を確認した。さらに、多点無線センサの電源を環境発電で置き換えることにも成功した。

画像処理AIについては、製造現場で必要とされる異常検知AIの基礎、アノテーションツールと説明可能AIについて調査・実験し、一定の結論を得るとともに企業支援のスキルを向上することができた。

これらの結果を用いて今後の地域企業への支援に役立てていきたい。

## 参考文献

- 1) 中居倫夫,小野仁,今井和彦,荒木武,小泉協,高野寛己,林正博,高田健一,沼山崇,坂下雅幸,佐藤裕高:IoTを用いたモノづくり工程管理高度化のための要素技術開発、宮城県産業技術総合センター研究報告、18、2021、p.27-30(文献内の「IoT体験キット」は本稿の「小電力無線センサキット」と同じ)
- 2) 小野仁,小泉慶雄,遠藤武聡:防災重点ため池の地震加速度の監視及びそのための簡易自立電源の開発、宮城県産業技術総合センター研究報告、19、2022、p.115(文献内の「IoT体験キット」は本稿の「小電力無線センサキット」と同じ)
- 3) 小野仁,今井和彦,太田晋一,荒木武:スイッチング回路を応用した省エネルギー・エネルギーハーベスティング技術の開発、宮城県産業技術総合センター研究報告、13、2015、p.6
- 4) 特許第6796843号「蓄電回路」(宮城県)

- 5) P. Bergmann, M. Fauser, D. Sattlegger, and C. Steger, “Mvtec ad-a comprehensive real-world dataset for unsupervised anomaly detection,” in CVPR, 2019.
- 6) <https://github.com/heartexlabs/labelImg>  
(参照 2023-07-10)
- 7) <https://github.com/wkentaro/labelme>  
(参照 2023-07-10)
- 8) <https://opencv.github.io/cvat/docs/administration/basics/installation/> (参照 2023-07-10)
- 9) J. Adebayo, J. Gilmer, M. Muelly, I. Goodfellow, M. Hardt, and B. Kim, “Sanity Checks for Saliency Maps Grad-CAM: Visual Explanations from Deep Networks via Gradient-based Localization” in 2018