

# 半教師あり学習画像AIによる生産品目判別・計量技術の検証

Application of Semi-Supervised Learning AI to Classification in Production Lines

## 生産ラインでのエネルギー原単位改善に向けた安価・簡便な生産情報の取得

工場での生産ラインのエネルギー原単位改善には、エネルギー使用情報に加え、品目や数量の情報が不可欠である。教師データ準備の手間が少ない半教師あり学習によって生成した画像AIと汎用的なエッジデバイスを組み合わせ、内製化により安価で簡便にリアルタイムで生産品目の判別・計量が可能なデバイスの実現性を見出した。



執筆者  
先端技術応用研究所  
情報技術グループ  
中村 剛

### 1 背景と目的

IoTやクラウドといったICT技術は様々な業種や分野の業務に進化をもたらした。中部電力ミライズにおいても、こうした技術を活用し、工場のユーティリティ設備であるコンプレッサの電力使用状況をリアルタイムでモニタリング・分析してチューニングを行うコンプレッサIoT最適運用サービス[1]など、新たなお客さま向けサービスの創出へと繋がった。一方で、生産設備の省エネ・運用改善支援サービス（エネルギー原単位の改善）では、電流や空気量といったエネルギー使用量に加え、ラインを流れるワークの品目や数量といった生産情報の収集が不可欠である。数量は近接スイッチなどで容易に把握可能だが、品目情報はお客さまの手書き帳票でしか提供されないなど、データの精度や入手性に課題があった。

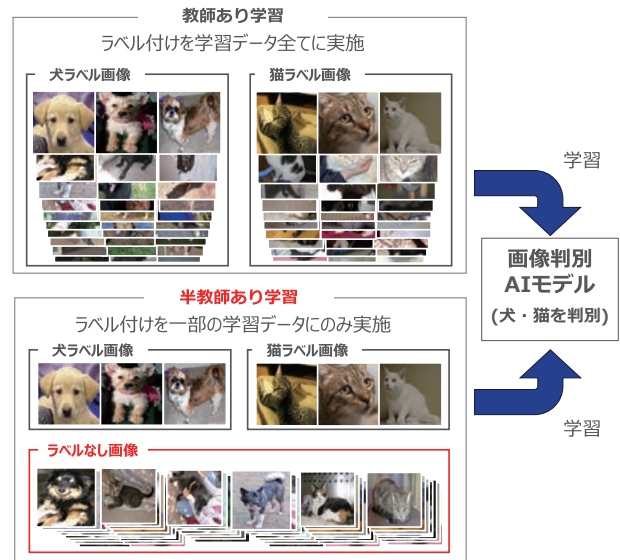
昨今のAI技術の進展は著しく、画像AIによる判別を利用すれば、生産ラインに設置したカメラ画像によりリアルタイムな品目判別・計量の実現が期待できる。しかしながら、一般的に画像AIを活用するには膨大な量の学習データ（教師画像取得＋ラベリング）が必要である。対象品目が毎回不特定であり、設置が短期間なお客さま生産ラインの省エネ支援の用途となると、都度大掛かりな学習データ準備とAIモデル改修は画像AI技術活用の大きなハードルとなる。

そこで、半教師あり学習AIのアルゴリズムを用いて、学習データ準備の手間やコストを極力抑えつつ、汎用デバイスやオープンソースソフトウェア（OSS）を活用した内製化により、安価で簡便な工場生産ライン向けの画像AI判別・計量デバイスの試作・評価を行った。

### 2 半教師あり学習AIの概要

半教師あり学習とは、少量のラベルありデータと大量のラベルなしデータを用いて学習させるAIモデル生成手法である。第1図に教師あり学習との比較の例を示す。犬と猫の判別を行うAIモデルを学習する場合、従来の教師あり学習では収集した教師画像のすべてに犬または猫のラベリン

グが必要であるのに対し、半教師あり学習では収集した教師画像の一部へのラベル付けでモデル学習が可能である。複数の半教師あり学習アルゴリズムを評価し、性能やパラメータ設定の容易さなどからFixMatch[2]を用いて開発を進めることとした。



第1図 教師あり学習と半教師あり学習の比較（例）

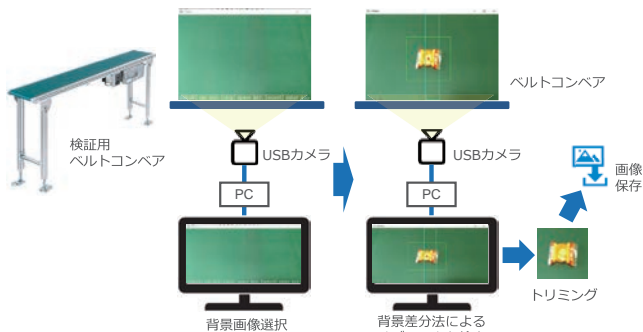
### 3 検証環境の構築と評価

学習データには、第2図に示す11種類の市販の煎餅菓子を生産品目に見立て、第3図のように背景差分法を用いてベルトコンベア上を流れる煎餅の画像をトリミングして保存した（各100枚x11種類）。



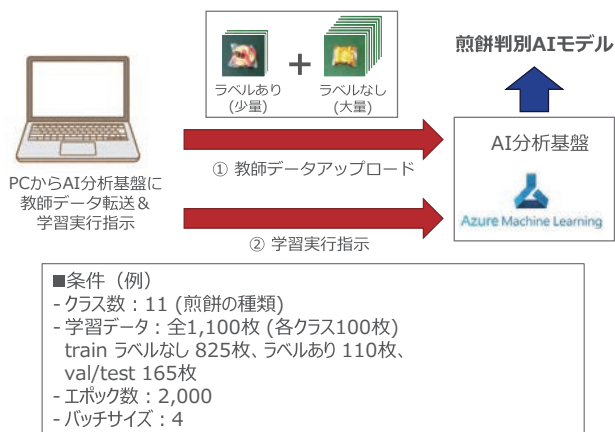
第2図 学習データ（煎餅11種類）

各クラスの画像のうち、一部にラベル付けを行い訓練および検証データに用いて、残りはラベルなし状態のまま訓練データとして利用した。ラベル付き枚数、および訓練/検証用の割合をパラメータとし、精度への影響の評価を行うこととした。



第3図 学習・検証データ画像収集方法

学習の実行には先端技術応用研究所で開発したAI分析基盤を用い、クラウド上でFixMatchを用いて煎餅判別AIモデルを作成した(第4図)。TeslaV100-1インスタンスを用いた場合の学習時間は9時間程度であった。



第4図 AI分析基盤を用いた半教師あり学習

煎餅判別モデルの判別精度評価には、学習データとは別に各クラス100個をランダムに流した動画を用い正解率を評価した(第1表)。各クラス25枚にラベル付けを行った場合、訓練割合によらず100%の正解率となった。10枚のみにラベル付けした際にも90%以上の高い正解率を維持していた。ただし、ラベル枚数と精度は必ずしも連動する結果とはならず、正解率にばらつきが生じた。

第1表 FixMatch学習モデルの正解率評価結果

| ラベル付枚数  | 正解率                        |                            |                            |
|---------|----------------------------|----------------------------|----------------------------|
|         | 訓練割合: 0.4<br>(訓練40% 検証60%) | 訓練割合: 0.6<br>(訓練60% 検証40%) | 訓練割合: 0.8<br>(訓練80% 検証20%) |
| 25枚/クラス | 100.0%                     | 100.0%                     | 100.0%                     |
| 20枚/クラス | 91.8%                      | 80.0%                      | 82.7%                      |
| 15枚/クラス | 100.0%                     | 100.0%                     | 99.1%                      |
| 10枚/クラス | 99.1%                      | 98.2%                      | 90.0%                      |

第2表には推論実行のエッジデバイスの種類による処理能力の比較を示す。GPUワークステーションが圧倒的な推論性能を発揮したが、GPUを搭載しないノートPCやGPU付きエッジデバイスのJetson Xavier NXでも画像切り出

しと推論時間を合わせて200ミリ秒程度で処理が完了しており、リアルタイムでの処理に十分利用可能な結果であった。Raspberry Pi4では1回の推論処理に5秒程度を要し、実用は厳しそうである。

第2表 エッジデバイス種類による処理能力比較

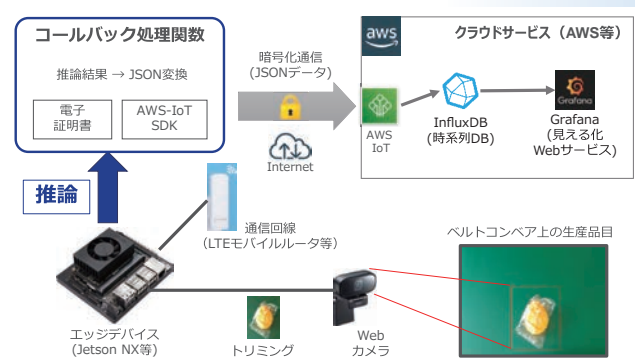
| デバイス  | 判別精度 (%) | 画像切り出し時間 (msec) | 推論時間 (msec)      |
|---|----------|-----------------|------------------|
| GPUワークステーション<br>(Core i7 CPU, 32GB RAM, GTX1080Ti 12GB GPU) | 100      | 15.42 ± 0.99    | 8.67 ± 1.33      |
| ノートPC<br>(Core i7 CPU, 16GB RAM)                            | 100      | 4.88 ± 0.90     | 197.9 ± 28.3     |
| Jetson Xavier NX<br>(ARM Carnel CPU, 8GB RAM, Volta GPU)    | 100      | 32.90 ± 2.34    | 163.22 ± 21.36   |
| Raspberry Pi<br>(ARM Cortex CPU, 4GB RAM)                   | 100      | 73.81 ± 3.30    | 4874.79 ± 189.99 |

## 4 今後の展開

検証結果からFixMatchを用いてAI学習の手間を低減するとともに、安価に生産ラインのワーク判別が可能な判別デバイスの実現性が見出せた。OSSの可視化ツールなどと組み合わせ、第5図のようなローカル環境での判別カウンタの構築や、第6図に示すようなクラウド上のサービス連携による遠隔でのモニタリングといった活用も可能である。



第5図 ローカル環境での判別モニタリング装置例



第6図 クラウド環境との連携例

今後、実際の工場ラインでの性能評価を行うとともに、様々なAI活用場面において、半教師あり学習を活用したAI学習の効率化にも取り組んでいきたい。

### 参考文献・引用

1. 中部電力プレスリリース「『〇(まる)っと』ちゅうでん コンプレッサIoT最速運用サービス」の提供開始について (2018年10月)
2. Kihyuk Sohn et al., "FixMatch: Simplifying Semi-Supervised Learning with Consistency and Confidence", arXiv:2001.07685 (2020)