

AI を活用した生産性向上の研究

長谷川 直樹* 大野 宏* 石澤 賢太*

Research on Productivity Improvement Using AI

HASEGAWA Naoki*, OHNO Hiroshi* and ISHIZAWA Kenta*

抄 録

コア技術高度化事業として、AI（人工知能）を活用した製造業の生産性向上に関する調査・研究に取り組んだ。外観検査自動化のための画像解析技術として、AI による不良品画像自動生成、視覚言語モデルの追加学習による不良判別の研究を行った。また、生成 AI の製造現場活用として、生産スケジュールの最適化、ノーコードツール活用手法について研究を行った結果を報告する。

1. 緒 言

AI（人工知能）の製造現場への活用は、人手不足対策、技能伝承、属人化解消に有効であり、企業の関心も高いが、技術習得が難しく、活用手法が確立されていない。近年、生成 AI の急速な発展により、様々なソリューションが提案されているが、製造現場への適用に際しては、現場特有の制約や要求条件などにより、解決すべき課題が多い。一方、当所はこれまで共同研究や技術支援を通じ、多くのテーマで AI の活用に取り組んでおり、さらに関連技術の調査・研究を進め、AI を活用した製造現場の生産性向上に関する技術シーズを確立することが本研究の目的である。

本稿では、画像解析技術として、AI の学習に使用する不良品画像の自動生成と視覚言語モデルのファインチューニングによる不良判別について、また、生成 AI の製造現場活用として、生産スケジュールの最適化とノーコードツールの活用について取り組んだ結果を報告する。

2. 外観検査自動化のための画像解析技術

2.1 不良品画像の自動生成

外観検査は品質保証に不可欠であり、当所では検査対象に応じて画像処理プログラムを作成

し、自動で外観検査を行うシステムの研究開発を行ってきた。10 年ほど前からは AI の発展によりディープラーニングを使い、良品・不良品の判別を行う方法に取り組んできたが、新潟県内で盛んな金属製品の検査では、不良品データの収集が難しいため、分類学習が困難な場合が多い。その解決策として、少量の欠陥データを基に画像生成 AI によって疑似的に不良データを大量に生成し、検査モデルの学習データに用いる方法がある。

本研究では、Stable Diffusion¹⁾を用いて疑似不良品画像を生成した。Stable Diffusion で使われている拡散モデルは、まず「きれいな画像」に少しずつノイズを加えて、最後はほぼ砂嵐の状態にしてから、その逆向きに「ノイズから元画像を復元する方法」を学習する。画像生成するときは、最初にランダムなノイズ画像を用意し、AI がノイズを少しずつ取り除きながら形や色を整えていき、途中で文章の指示を手がかりにして、望む内容の画像へ誘導し生成する。今回の検証では、少量のデータを用いてファインチューニングを行う LoRA²⁾ (Low-Rank Adaptation) を用いた。この手法は、大きなサイズのモデルにアダプタと呼ばれるネットワーク層を追加し、もとのパラメータは凍結し、追加したアダプタ部分だけを学習する。そのため、学習すべきパ

* 技術統括センター

ラメータ数が大幅に削減され、大容量の GPU がなくてもファインチューニングが可能になる。

2.2 視覚言語モデルの活用

視覚言語モデル (VLM : Vision Language Model) は、画像・動画等の視覚情報とテキスト等の言語を関連付け、両者を理解・生成する AI モデルである。ここでは、VLM として、画像とテキストを組み合わせた高度な対話や分析が可能なマルチモーダル AI モデルで幅広い機能と応用性を備えている LLaVA³⁾(Large Language and Vision Assistant) に着目した。LLaVA は、製品の外観検査や不良品の検出において、人間の目では見落としがちな微細な欠陥も正確に検出することができる⁴⁾とされている。

画像と質問文を VLM に渡すと回答文が出力される。この方法を活用し、外観検査の自動化のための良品・不良品判定及び不良種類の判別に取り組んだ。

2.3 ファインチューニングによる不良判定

LLaVA のモデルをファインチューニングし、チューニングガム画像の不良判別を行った。対象データセットは、VisA⁵⁾(Visual Anomaly dataset) の Chewinggum を使用した。良品画像 503 枚、不良画像 100 枚からなり、不良画像は、図 1 のようにシミ、欠け、穴、キズの 4 種類の不良が予めラベル付けされている。データセットの前処理は、文献⁶⁾を参考にし、学習用、評価用のデータセットを作成した。




図 1 Chewinggum の不良画像

表1 ファインチューニングの設定

モデル	Pre-Trained Weights: llava-v1.5-7b
学習データ	良品493枚, 不良各10枚程度を計328枚に拡張
評価データ	良品10枚, 不良各2~4枚, 合計22枚
プロンプト	<image>\n You are a classifier. Output only one token: normal, similar colour spot, ..., scratches.

ファインチューニングの諸条件を表 1 に示す。学習に利用できる不良画像が少ないため、不良画像を複数回使用し、不良が全学習データの 4 割になるように拡張した。前記 LoRA と、学習を高速化し効率的に処理するための DeepSpeed を使用した⁷⁾。ここでのポイントは学習時に設定するプロンプトであった。自然言語を回答する VLM にクラス判定を行わせるため、classifier であること、一単語だけ回答させることを明示する必要があった。また、ソースコードを修正し、学習中に途中の評価結果を計算する機能を追加した。学習過程の予測誤差、予測精度の推




図 2 学習過程

移を図2に示す。評価データによる予測精度は100%であった。また、2.1 節と同様に自動生成した不良品画像を用いてデータ拡張し、ファインチューニングを行う方法についても有効性を確認した。

3. 生成 AI の製造現場への適用

3.1 生産スケジュールの最適化

生成 AI の性能向上に伴い、DX 推進に取り組んでいる企業から生産スケジュール最適化に関する相談が増えている。生産スケジュールの作成は依然として属人化が残り、市販ソフトがあるものの導入障壁が高い。

生産計画の中核は、一般的にデータ整備と数理最適化で実現する。生成 AI・AI エージェントは、マスタ整備支援、欠損・矛盾データの検出、入力作業の半自動化といった前工程の効率化で効果が出やすく、最適化のコア部分は数理最適化が使われている。市販ソフトの導入は高機能なために使いこなしが難しいだけでなく、使える人が限られるため、属人化する傾向にあり、コストも高い。そこで、Python を使った自社業務適合型の段階導入が推奨されている。多品種・現場制約など固有条件への適合性が高い、不要機能を排し、投資対効果を明確化できる、利用者を限定しない運用設計（現場定着）にしやすいなどの特徴がある。

Google が提供している最適化ツールである「OR-tools」を使い、簡単な条件で最適な生産スケジュールを作成できるか試みた。図 3 に示す条件で、早く生産が完了し、工程の変更回数をできるだけ少なくするよう生産スケジ

- ①製品 P1 を 10 個、P2 を 15 個作る。
②製品 P1 の工程は A（所要時間 20 分），次が B（20 分），最後が C（20 分）で，製品 P2 の工程は A（20 分），次が B（20 分）で，順番を厳守して加工する。
③作業者は 3 人で，W1 は工程 A が，W2 は工程 A と B が，W3 は工程 A と B と C が可能である。
④装置は 3 台で，M1 は工程 A を，M2 は工程 A と B を，M3 は工程 A と B と C を加工できる。
⑤段取り替えと加工品の移動時間はゼロで計算する。

図 3 生産スケジュール作成の条件

ュールを作る Python プログラムを作成した。結果を図 4 に示す。この図の縦軸は作業者 W1～W3 を，横軸は時間を示し，1 コマ 20 分で生産時間は 420 分と最適な結果が得られた。また，P1-1-A は，製品 P1 の 1 個目の A 工程を意味する。一方，段取り替えの回数は 3 回と最適な値ではなかったため，手作業により 2 回に減らした。

3.2 ノーコードツールの活用

当所のこれまでの生成 AI 活用の研究では，Python でプログラミングしていたが，言語習得の壁が高いことが課題であった。一方，最近は無コードで生成 AI アプリを開発するツールが普及している。

Dify[®]（ディファイ）は，生成 AI アプリを容易に作成して運用できるプラットフォームである。公式ドキュメントでは，Dify を「オープンソースの Agentic Workflow 構築基盤」と位置づけ，視覚的なフロー設計，既存ツール，データ接続，デプロイまでを統合している点

0	1	2	3	4	5	6	7	8	9	10	11	12	13	14	15	16	17	18	19	20	21
W1	P1-1-A	P1-2-A	P1-3-A	P1-4-A	P1-5-A	P1-6-A	P1-7-A	P1-8-A	P1-9-A	P1-10-A	P2-3-A	P2-4-A	P2-5-A	P2-7-A	P2-9-A	P2-11-A	P2-12-A	P2-13-A	P2-14-A	P2-15-A	
W2		P1-1-B	P1-2-B	P1-3-B	P1-4-B	P1-5-B	P1-6-B	P1-7-B	P1-8-B	P1-9-B	P1-10-B	P2-1-B	P2-2-B	P2-3-B	P2-4-B	P2-5-B	P2-7-B	P2-9-B	P2-11-B	P2-13-B	P2-15-B
W3	P2-1-A	P2-2-A	P2-6-A	P2-8-A	P2-10-A	P1-1-C	P1-2-C	P1-3-C	P1-4-C	P1-5-C	P1-6-C	P1-7-C	P1-8-C	P1-9-C	P1-10-C	P2-6-B	P2-8-B	P2-10-B	P2-12-B	P2-14-B	

図 4 最適化された生産スケジュール（段取り替え：黒地に白抜き）

が特徴である。チャットボット，エージェント，ワークフロー，チャットフローなどを視覚的に容易に構築できる。また，言語モデルも選択でき，情報漏洩の心配のないローカル環境に構築することも可能である。しかし，Python でシステムを作る場合に比べて，細かいカスタマイズに限界がある，非常に大きいデータを扱う場合は不向きである，完全ノーコードとはいえない（時々Python の知識が必要）等の課題もある。

4. 県内企業の状況

新潟県は経済産業省が実施している DX 認定制度への申請支援事業に取り組んでおり，DX 推進に取り組む県内企業も増えている。

生成 AI の活用では，プログラミング，調査，技術的な相談（壁打ち）などに利用する企業は増えているが，AI エージェントの活用による業務の自動化・省力化に取り組む企業は少ない。その要因として，IT 関連以外の企業ではこれらで何ができるのかよく分からないこと，システムを自社で開発するには Python を習得する必要があることが壁になっている。

当所では，ノーコードツールの普及が鍵になると考え，Dify の講習会や生成 AI 活用の講演会を開催した。その中で，業務の自動化・省力化に生成 AI を活用したいとの相談があり，今後，共同研究事業等で支援していく予定である。

5. 結 言

(1) AI による不良品画像自動生成，視覚言語モ

デルの追加学習による不良判別の研究を行い，有効性を確認した。

(2) 生産スケジュールの最適化，ノーコードツール活用について調査・研究を行い，生成 AI の活用手法を検討した。

(3) 県内企業のニーズを調査し，今後の支援の方向性を確認した。

参考文献

- 1) Robin Rombach, et al, “High-Resolution Image Synthesis with Latent Diffusion Models”, arXiv pre-print arXiv:2112.10752, 2022.
- 2) Edward J.Hu, et al, “Lora:Low-rank adaptation of large language models”, arXiv preprint arXiv:2106.09685, 2021.
- 3) LLaVA: Large Language and Vision Assistant, <https://github.com/haotian-liu/LLaVA>, (閲覧 2026-2-10).
- 4) LLaVA とは？アーキテクチャ・特徴・マルチモーダル競合との比較を徹底解説！, <https://ai-market.jp/services/llava/>, (閲覧 2026-2-10).
- 5) Visual Anomaly (VisA): <https://registry.opendata.aws/visa/>, (閲覧 2025-10-10).
- 6) 進藤佑樹, “第 4 部 生成 AI を活用したデータ拡張による異常分類モデルの精度検証”, インターフェース, 2025 年 3 月号 (2025), pp.79-93.
- 7) How to Fine-Tune LLaVA on a Custom Dataset, <https://wandb.ai/byyoung3/ml-news/reports/How-to-Fine-Tune-LLava-on-a-Custom-Dataset--Vmlldzo2NjUwNTc1>, (閲覧 2026-2-10).
- 8) Dify, <https://dify.ai/jp>, (閲覧 2026-2-26).