

AI化推進方法と、実現に向けた技術開発

生産システム革新センター AI推進室 黒澤 公紀・仁田脇 貴浩・チャン ドウック ソン

Methods for Promoting AI and The Technological Development for Its Realization

K. Kurosawa, T. Nitawaki, and Tran Duc Son

ディープラーニングを主としたAI導入は進みつつあるが、製造工程に対してはPoCに留まることが多い。当社では、製造工程へのAI導入を効率的に進めるためのAIロードマップを作成し、これに基づきAIシステムの検討/開発/導入/運用を進めている。本稿では、当社のAI取組みの進め方、具体的案件の内容、案件を実現するために開発した技術について説明する。また、5G等の新技術動向を踏まえ、AIシステムアーキテクチャの方向性を考察する。

The application of AI, mainly deep learning, has been progressing, but often get stuck at PoC step in the manufacturing process. To efficiently introduce AI into the manufacturing process, we have defined our AI roadmap and based on this, we are studying, developing, implementing and operating an AI system at our company. In this paper, we will explain how we are putting effort into AI, the details of specific projects, and the technologies we have developed to implement them. We will also discuss the direction of AI system architecture based on new technology trends such as 5G.

1. ま え が き

近年、AIを事業に適用した事例は増えてきており、具体的な効果も確認されてきている。一方、製造業、特に製造工程へのAI導入は進んでおらず、PoCの段階に留まることが多い。

当社では、2015年からAI研究に着手し、製造工程へAIを適用するための技術開発を進めてきた。さらに2018年以降、製造工程へのAI導入を開始し、順次対象を拡大してきている。

本稿では、AI技術の動向を踏まえ、当社におけるAI取組みのコンセプト、取組み事例、開発/導入した導入技術について報告する。また、5G等の新技術の動向を考慮し、AIシステムアーキテクチャの方向性を考察する。

2. AI技術の動向

過大な期待と現実/実力とのギャップが、一般的に、ブームと冬の時代を生み出してきている。AIについても、これまでブームと冬の時代を繰り返してきた。(図1)

第1次AIブームは、コンピュータが誕生してから約10

年後、1950年代に始まり、1970年代にかけて続いた。

第1次AIブームでは、既に現在のAI技術につながるほとんどの理論が提唱されている。一方、コンピュータへの実装技術やコンピュータ自体の性能が大きく不足し、実現できたのは単純なゲーム等であった。そのため、AIに対する期待に実力が追いつかず、第1次AIブームは終焉した。

LispやPrologなどAIを実装しやすい特徴を持つコンピュータ言語の利用拡大、知識を格納するための知識ベースの構築、知識を扱う推論エンジンの実現が、1980年代に第2次AIブームを形成した。専門家に代わり意思決定を行うエキスパートシステムが代表例である。一方、知識ベースに知識を登録するための形式知化や登録作業は、人間が行う必要があった。さらに新たな知識の追加や、知識間の整合性確保など、多くの労力が継続的に必要となるため、知識ベースの維持が困難になり、第2次AIブームは終焉した。第2次AIブーム終焉の要因は、知識獲得を人間に全面的に依存していたことである。

2000年代になり、インターネットの発達で、情報量の爆発的増加と蓄積を進めた。さらにコンピュータ性能も飛躍的に向上した。これらを背景に、AI自身による知識の自律的学習を可能とするディープラーニングと強化学習が

略語・専門用語	正式表記	説明
AI	Artificial Intelligence	人工知能
Lisp	Lisp/LISP	プログラミング言語
Prolog	Prolog	プログラミング言語
エキスパートシステム	Expert System	専門家の意思決定能力をエミュレートするコンピュータシステム
Mycin	Mycin	医学分野に用いられたエキスパートシステム
知識ベース	knowledge Base	知識管理のためのデータベース
ディープラーニング	Deep Learning	多層のニューラルネットワークを用いる機械学習手法
強化学習	Reinforcement Learning	現在の状況から取るべき行動を決定する問題を扱う機械学習手法
PoC	Proof of Concept	概念検証
CNN	Convolutional Neural Network	画像や動画認識に用いられるディープラーニングの一種
物体検出	Object Detection	デジタル画像・動画内に映る特定の物体を検出する技術
リカレント	Recurrent Neural Network	時系列データに用いられるディープラーニングの一種
マルチモーダル	Multimodal Deep Learning	画像や音声、文字など異なるデータを組み合わせて学習するディープラーニングの一種
Sim2Real	Simulated to Real	シミュレーションを用いて現実世界の課題を解く機械学習手法の一種
蒸留	Distillation	既存のAIモデルを用いて、別の（例えばよりコンパクトな）AIモデルの学習を行うこと
GW	Gateway	異なるネットワーク同士で、データの中継を担う機器・ソフトウェア
FA網	Factory Automation Network	工場内の装置制御を行うためのネットワーク
IP網	Internet Protocol Network	IPを利用して通信を行うコンピュータネットワーク
エポック数	Epoch	AIが学習を実行する回数の単位
エッジAI	Edge Artificial Intelligence	現場で動作するAIシステム及びそのAIシステムが動作するコンピュータ
リコートファイバ	Recoat Fiber	被覆を除去した後に再被覆を行った光ファイバ
クラス分類	Classification	画像などのデータを有限個のカテゴリに分類する機械学習の課題
Transformer	Transformer	主に自然言語処理の分野で使用されるディープラーニングの一種 近年研究が進み自然言語処理以外の分野にも応用されている
UPS	Uninterruptible Power Supply	安定した電力を供給する装置

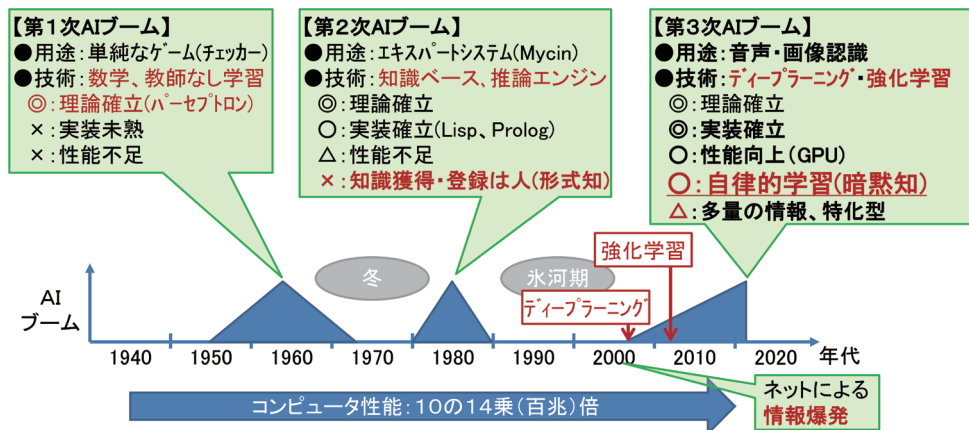


図1 AIの歴史と第3次AIブームの本流

Fig. 1. History of AI and the mainstream of third boom.

実装された。これらが第3次AIブームの本流である。一方、ディープラーニングや強化学習で得た知識は、そのAIでしか分からない暗黙知のため、人にとってはブラックボックスである。また、知識獲得のために正確で多量な情報を要することや、特定目的に特化しているなどの問題があり、更なる進化が求められている。

AIには様々な技術があるが、当社で取組んでいるのは、第3次AIブームの本流であるディープラーニングと強化学習であり、以下の章で記載するAIとは、すべてディープラーニング、または強化学習を意味している。

3章でAI取組みのコンセプト、4章で具体的な取組み事例と導入した技術、5章ではAIシステムアーキテクチャについて説明する。

3. AI取組みのコンセプト

一般的にAIシステムについては、個々のシステムに着目して論じられることが多いが、当社では、AI取組み全体像を最初に明確化することで、AI取組みの方向性を定め、取組み全体を効率的に進めるよう努めている。全体像において明確化すべき観点は、次の通りである。

- ①AIが、製造業におけるモノづくり革新で果たす役割を明確化すること（3.1章）
- ②AI技術の高度化と、製造業でのAI利用拡大の進め方（ロードマップ）を明確化すること（3.2章）

3.1 モノづくり革新モデル

製造業におけるモノづくり革新で、AIの役割を明確化するためモノづくり革新モデルを作成した（図2）。

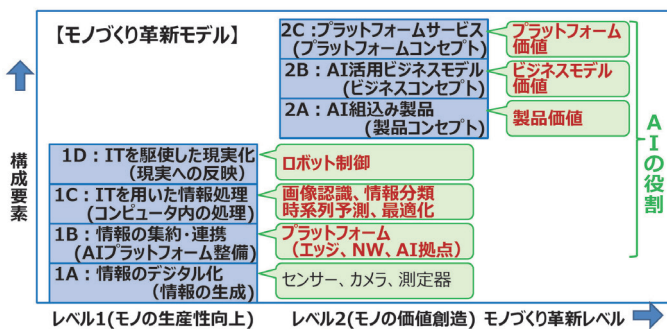


図2 モノづくり革新モデル
Fig. 2. Innovation model for manufacturing.

(図2)において、モノづくり革新の対象を二つのレベルに分けている。レベル1はモノづくりプロセスにおけるQCDの飛躍的向上、レベル2はモノそのものの価値創造とし、それらを図の横軸に記述している。

レベル1の構成要素が連携することで、QCDの飛躍的向上が可能となる。代表的な連携例は、AIを用いたカイゼンである。製造業においてカイゼンはきわめて有益であり、多くの効果を生んできている。一方、人を中心としたカイゼンでは、情報量は人が扱える範囲の少ない量であることや、人の移動や調査などのためカイゼン速度に限界が生じる。従って、人がボトルネックとなり、多くの情報を扱うことや、カイゼンプロセスを高速で回すことができない。これに対し、情報をデジタル化し、収集し、AIを用いて分析予測、制御することで、多量の情報を扱うことや、高速でカイゼンプロセスを回すことが可能となり、QCDの大幅向上が実現できる。

ただし現在のAI技術では、人によるカイゼンとAIによるカイゼンを比較した場合、人によるカイゼンの方が着眼点等で優れていることも多い。従って飛躍的なカイゼンを実現するには、人によるカイゼンとAIによるカイゼンの両輪を進めることが重要である。これを従来のカイゼンと対比して超カイゼンと定義している（図3）。

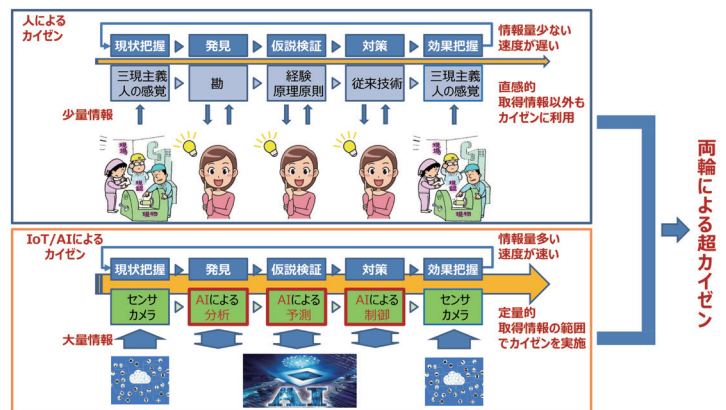


図3 人とAIによる超カイゼン
Fig. 3. The improvement by human and AI.

(図2)におけるレベル2の価値創造とは、これまでとは異なる新たなコンセプトを見出し、モノやビジネスそのものの価値を高めることである。2Aは、モノにAIを組込むことで、製品に新たな価値を付加すること。2Bは、モノのサービス化やモノを用いたビジネス自体にAIを適用することで、新たなビジネスモデルの創出やビジネスモデルの価値を飛躍的に高めること。2Cは、一つのビジネスモデルに多数のステークホルダーが共存できるプラットフォームや、複数のビジネスモデルが共存できるプラットフォームを構築することである。

一般的にAIの役割に、1B：情報の集約/連携は含まないが、当社では1BをAI主導で進めており、これをAIプラットフォームと呼んでいる。AIプラットフォームについて

は、4. 5. 1章で説明する。

3. 2 AIシステム開発ロードマップ

AIの進化は急速で、技術的な難易度の差も大きい。自社の実力に応じて取組み対象を決め、取組みを通して技術レベルを高めることが重要である。そのため、AI技術の高度化とAI利用領域の拡大をどのように進めたら良いかを明確化するために、AIシステム開発ロードマップを作成している(図4)。

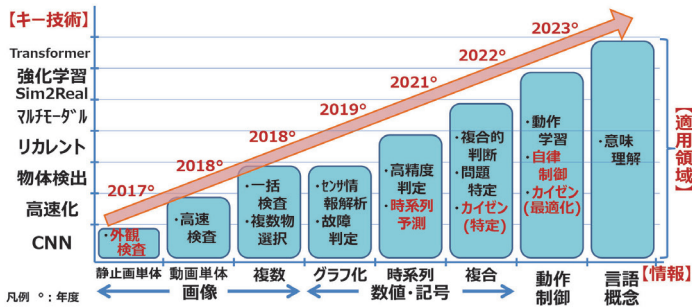


図4 AIシステム開発ロードマップ

Fig. 4. AI system development roadmap.

(図4)において、横軸はAIが扱う情報、縦軸はその情報を扱う上でキーとなる技術である。また情報とキー技術により実現可能な利用領域を棒グラフ内に記載している。数字はAIシステムの運用開始/予定時期である。

横軸のAIが扱う情報は、「画像」、「数値・記号」、「動作・制御」、「言語・概念」の4分類としている。画像は、「静止画単体」、「動画単体」、「複数」の3分類としている。「数値・記号」は、「グラフ化」、「時系列」、「複合」の3分類としている。これらは、技術的難易度の低い方から順に記載している。

縦軸は、横軸の情報を扱う上でキーとなるAI技術である。具体的には、静止画単体に対してはCNN、動画単体に対しては蒸留等の高速化技術、複数に対しては物体検出技術、時系列に対してはリカレント、複合に対してはマルチモーダル、動作・制御に対しては強化学習・Sim2Real、言語・概念に対してはTransformerである。

棒グラフ内の利用領域において、外観検査、時系列予測、カイゼン、自律制御を特に重要な領域としている。

4. AI適用の実例と開発した技術

4. 1 取組み案件一覧

AIロードマップに基づき、キー技術の理解と開発を段階的に進めている。2021年1月現在で取組み中の案件を、(図4)と同じ横軸上に記載する(図5)。縦軸は案件の状態(工程)を示している。図内に章番号を記載している案件については、次章以降で説明する。

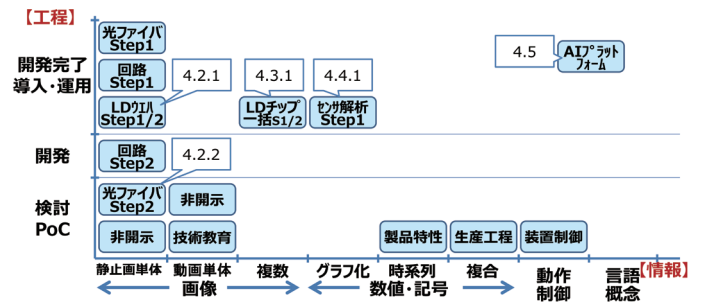


図5 取組み案件一覧

Fig. 5. List of projects.

4. 2 静止画単体

“静止画単体”とは、画像の中に動かない被写体が一つだけある情報である。キー技術はCNNであり、この技術を用いて被写体が何に分類されるかを判定、即ち画像認識を行うことができる。製造業においては、主に画像を用いた外観検査に用いられている。

4. 2. 1 レーザダイオードウエハ外観検査

本章では、高出力レーザーダイオード素子生産工程に導入したレーザーダイオードウエハ外観検査システムについて説明する。このシステムは、オプトエナジー株式会社と共同で開発/運用している。

4. 2. 1. 1 これまでの業務概要と課題

生産工程(図6)には、3回の検査がある。本システムは、①外観検査1を、AIを用いて自動化したシステムである。なお、②外観検査2は、4. 3. 1章で説明する。




図6 高出力レーザーダイオード素子生産工程概要

Fig. 6. The production process of laser diode element.

検査に本システムを適用するまでは、素子の構造等に精通した技術者が、クリーンルーム内で目視検査を実施していた。長期信頼性まで加味して良品/不良品を判定するため、場所、形、大きさ、色の組合せによって良品/不良品の判定が異なる（図7）など、判定の難易度が高い。

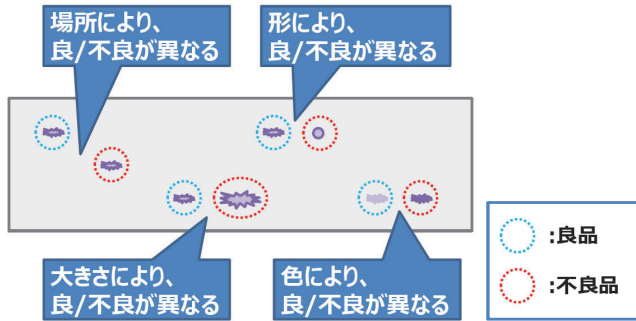


図7 良品/不良品の判定ルール
Fig. 7. Rule for quality judgment.

4. 2. 1. 2 システム概要

本システムのハードウェア構成図を（図8）に示す。構成要素は、撮像装置、エッジAIであり、クリーンルーム内に設定される。エッジAIはFA網に接続され、GWを経由してIP網に接続し、AI拠点のAIプラットフォームに接続される。エッジAIは撮像装置の制御を兼ねており、そのOSにあわせてWindowsで動作している（表1）。

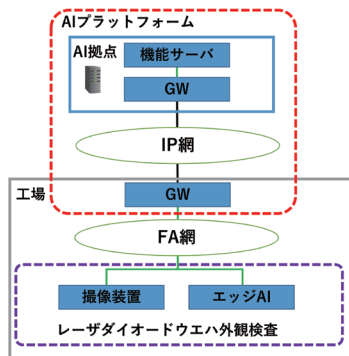


図8 システムのハードウェア構成
Fig. 8. Hardware configuration of the system.

表1 エッジAIのソフトウェア構成

Table 1. Software environment of AI edge devices.

区分	ソフトウェア
OS	Windows
ディープラーニングフレームワーク	Keras, TensorFlow
GPUプラットフォーム	CUDA
プログラム言語	Python
ネットワークモデル	EfficientNet

4. 2. 1. 3 AI適用状況

システム動作フローを（図9）に示す。①ウエハを顕微鏡にセット後、自動的にステージを動かしつつ複数枚の写真を撮影する。②複数の写真からウエハ全体の画像を合成する。③合成したウエハ画像からチップ単位の画像を切出す。④切出したチップ画像にAIを用いてクラス分類を行う。この時、製造工程のカイゼンのために、良品/不良品ともに、複数のクラスに分類する。⑤検査結果は、人が分かりやすい形式で表示する。




図9 レーザダイオードウエハ外観検査 動作概要
Fig. 9. Operation overview.

良品/不良品の例を（図10）に示す。上段は良品、下段は不良品の例であり、微細な違いで良品/不良品となる。



図10 レーザダイオードウエハ外観検査判定例
Fig. 10. Example of judgment.

4. 2. 1. 4 導入技術

本システムに導入した、額縁方式、ヒートマップ、学習状況可視化の3つの技術について説明する。

額縁方式は、ウエハ全体画像からチップ画像を切出す際に用いる技術である。ウエハ撮影時に、カメラのピクセル列とチップの縁を完全に平行にすることは困難である。そのため、ピクセル列に沿ってチップを切出すと、チップは斜めに切出される。さらに切出しサイズは斜め度合いにより変化する。画像をCNNで解析する場合、画像サイズを統一する必要がある。そのため、切出し後に統一サイズになるよう画像を拡大/圧縮する手法があるが、微細な変異のサイズも変わるため、本案件には適用できない。

そのような場合には、切出し前に切出し対象をピクセル

列と平行になる様に回転する手法がとられる。このとき、回転により段差が生じる（図11）ため、段差が目立たないようにスムージング処理を行うことが多い。



図11 画像切出し時の段差問題

Fig. 11. Misalignment problem when cropping images.

一方、本案件のようにピクセル単位の微細な差異で判定が変わる場合は、スムージング処理により変化が鈍されると判定精度が低下する。この問題解決のため、対象物より大きな統一の範囲で切出しを行い、対象物を回転せずAIに入力することとした。さらに、大きなサイズで切出す場合、周囲の物が切出し範囲に入り込むことがあるため、周囲の物を検知し特定の色で塗り潰している。この技術を額縁方式と呼んでいる（図12）。




図12 額縁方式

Fig. 12. Frame formation.

ヒートマップは、AIがどの場所に注目してクラス分けを行ったかを可視化する技術である。現在の技術では、判定根拠を論理的に示すことは困難である。一方、判定根拠を示さずに、AIの判定を利用者に納得してもらうのは難しい。この問題解決のため、AIがクラス分けする時に注目する画像の箇所を、注目度に応じて色分け表示することとした。ただしレーザダイオードチップの画像は、製造上、開示できない事項を含んでいるため、圧着端子を例に説明する（図13）。




図13 ヒートマップによる推論根拠の可視化

Fig. 13. Visualizing the reason of inferences.

（図13）において、左側の画像で線が飛び出た箇所が変異箇所であり、人はこの場所に着目して判断する。ヒートマップを用いてAIの着目箇所を示したのが右側の画像である。左右の画像で人とAIの着目箇所が一致しており、人はAIの判定根拠を視覚的に認識できる。

学習状況可視化は、次元圧縮を用いてAIの学習進行状況を可視化したものである。AIの学習状況を数字やグラフでステークホルダーと共有しても、学習状況がイメージしにくく、AI精度に対する不安を解消できない。これが、AIシステム導入が進みにくい要因の一つでもある。この問題を解決するため、次元圧縮を用いた学習状況の可視化を導入した。（図13）と同じ事例で説明する（図14）。




図14 学習状況可視化1

Fig. 14. Visualizing the learning progress (1).

（図14）では、学習の進行状況をエポック数の少ない順に表示している。④では一部に混在はあるが、⑤では完全に分離されている。この図をステークホルダーと共有することで、学習状況を理解されやすくなった。

さらに（図15）は、学習の進行状況に画像をマッピングしたものである。間違えやすい画像や、学習が少ない画像を確認でき、AI精度向上にも活用できる。

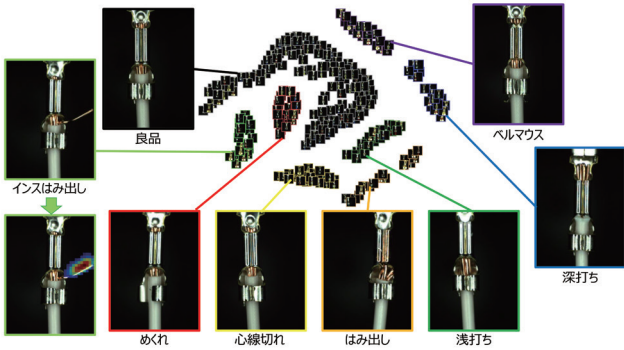


図15 学習状況の可視化 2

Fig. 15. Visualizing the learning progress (2) .

以上の技術を用いることにより、人の精度（95%）に対して、99.75%のAI精度達成している（表2）。

表2 AIの判定精度

Table 2. Accuracy of AI judgment.

テスト：4万チップ以上 正解率：99.75%	A I	
	良品	不良品
正解	良品 96.46 % 不良品 0.12 %	良品 0.12 % 不良品 3.29 %

4. 2. 2 光ファイバ外観検査システム

リコートファイバ検査に、AIを適用した事例を説明する。ただし、システム構成等は非開示のため割愛する。

4. 2. 2. 1 課題

光ファイバを精緻に検査する場合、目視で検査を行う。（図16）の上段は良品、中段/下段は不良品の例である。




図16 光ファイバ外観検査判定例

Fig. 16. Example of visual inspection of optical fiber.

光ファイバ等では、光源位置/カメラアングル/変異点種類/変異点の位置等の条件により、同じ個所が良品に見えたり不良品に見えたりすることがある（図17）。①は良品であるが、中段画像だけ不良品に見える例である。②は不良品であるが、中段画像だけ良品に見える例である。




図17 条件の違いによる変異点の見え方

Fig. 17. How the mutation look under different conditions.

4. 2. 2. 2 導入技術

（図17）の問題を解決するため、撮影条件を変えて撮影した複数画像を1枚の画像に合成し、AIで判定する技術（多視点解析）を開発した。（図18）は、本技術の実行例である。多方向から撮影した画像を合成することで、良品/不良品判定を高精度で実行できている（表3）。




図18 多視点解析による判定例

Fig. 18. Example of multi-viewpoint analysis.

表3 AIの判定精度

Table 3. Accuracy of AI judgment.

全周の正解率 98.75% (3,147件)	A I	
	良品	不良品
正解	良品 27.50 % 不良品 1.25 %	良品 0.0 % 不良品 71.25 %

4. 3 複数

“複数”とは、動く/動かないによらず複数の被写体が画像中にある情報である。キー技術は物体検出であり、被写体を特定できる。製造業において、被写体の数を調べる場合や、個々の被写体の良否判断をする場合に用いられる。

4. 3. 1 レーザダイオードチップ一括検査システム

本章では、レーザダイオードチップ一括検査システムについて説明する。(図6)に記載した②外観検査2を、AIを用いて自動化した。システム構成、動作フローは、4.2.1章とほぼ同一のため割愛する。本システムも、オプトエナジー株式会社と共同で開発/運用している。

チップの良品/不良品の例を(図19)に示す。上段は良品、下段は不良品の例である。(図20)に検査結果を示す。検出したチップが良品であれば緑色、不良品であれば赤色の枠取りで表示する。劈開ミスの場合、様々なチップ形状や破片が生じるため、プレートマッチングを用いた従来技術では、確実な物体検出は難しい。




図19 良品/不良品の例

Fig. 19. Example of good and bad products.




図20 検査結果の表示

Fig. 20. Display of inspection results.

4. 3. 1. 1 導入技術

画像サイズの拡大に伴い、AIを用いた物体検出に必要なメモリ量や処理時間は増大し、システム費用が高くなる。この問題に対応するため、物体検出とクラス判定を分離し、それぞれに適した画像サイズでAI判定することで、この技術を使わずに物体検出を行う場合と比較して、コンピュータリソースを削減しつつ判定精度高める技術を開発した。(図21)において、①検査対象物中の変異点が微細なため、検査画像は約5000万ピクセルと大きなサイズで撮影する。②①の画像サイズで物体検出を実施すると多くのコンピュータリソースが必要なため、約9万ピクセルまで画像を圧縮し、③物体検出のみを実施する。④検出

した検査対象物を元の画像サイズに戻しクラス判定を行う。この技術により、コンピュータリソースを削減しつつ、高い判定精度を実現した(表4)。




図21 物体検出におけるリソースと処理時間

Fig. 21. Resources and processing time of object detection.

表4 外観検査2 正解率

Table 4. Visual inspection 2 : accuracy.

物体検出率	100.0 %
良/不良正解率	99.6 %

4. 4 グラフ化

“グラフ化”とは、数値/文字/記号を、図形の位置/形状/色に変換した情報である。キー技術はCNNである。製造業においては、センサ出力情報や各種パラメータから、状態の良否を判定する場合等に利用できる。

4. 4. 1 センサデータ解析システム

本章ではセンサデータ解析システムについて説明する。

4. 4. 1. 1 これまでの業務概要と課題

製造現場には多数のセンサが設置されており、これらのデータを集約/蓄積して時系列グラフ化し、異常の有無を判定する業務がある。さらに閾値判定だけでなく、グラフの微妙な変異から判定する場合もある(図22)。従来技術でこれらを実現するためには、微細な変異を定義し、検出アルゴリズムを作成する必要があるが、様々な変異があるため、すべてのアルゴリズムを作成することは困難である。そのため、これまで熟練者に頼ってきたものの、少子高齢化等により人材確保が難しくなっている。この問題を解決するために、本システムを開発した。

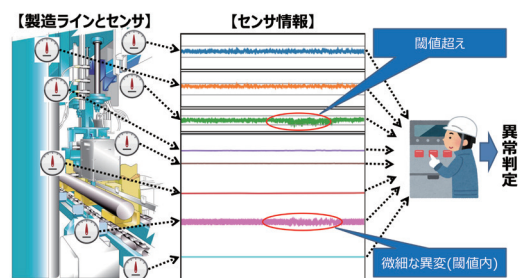


図22 センサデータ解析

Fig. 22. Sensor data analysis.

4. 4. 1. 2 システム構成

ソフトウェア構成は（表 5）に示す。なおハードウェア構成は割愛する。

表5 エッジAIのソフトウェア構成

Table 5. Software environment of AI edge devices.

区分	ソフトウェア
OS	Ubuntu
ディープラーニング フレームワーク	Keras, TensorFlow
GPUプラットフォーム	CUDA
プログラム言語	Python
ネットワークモデル	MobileNet v 2 ベース

4. 4. 1. 3 AI適用状況

センサは長時間連続して動作する事が多く、そのままグラフ化すると長大なグラフになる。またグラフ内に複数の変異点が存在する可能性も高まる。そのためAI適用のために、センサデータを一定の間隔で区切り、複数の分割グラフ画像とし、分割画像単位でタグ付け/学習/推論することとした。ただし、変異点が 2 枚の分割画像に分断されることで精度が低下しないように、分割グラフ画像は一定幅でオーバーラップさせている。また一定の間隔については、分割グラフ画像内に複数の変異点が極力入らないことと、一つの変異点が極力複数の分割グラフ画像に跨らないことを考慮し、決定している（図 23）。




図23 グラフの分割方法

Fig. 23. How to divide the graph.

4. 4. 1. 4 導入技術

一般的に、被写体位置を精緻に検出することはCNNでは難しい。本システムでは規格値判定を精緻に行うため、閾値を示すガイド線をグラフ内に引くことで、AIにガイド線とグラフとの関係を学習させ、判定精度を高める技術を開発した（図 24）。判定精度を（表 6）に示す。

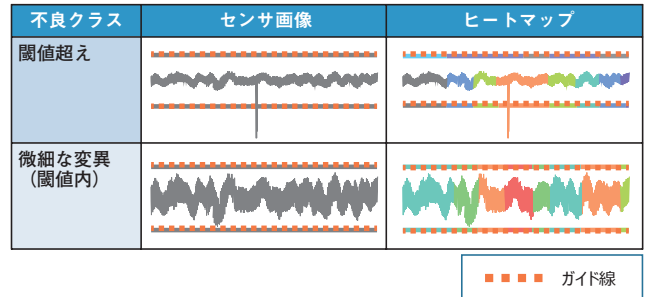


図24 ガイド線と判定結果

Fig. 24. Guide line and judgment result.

表6 AIの判定精度

Table 6. Accuracy of AI judgment.

		A I	
		良品	不良品
正解	良品	31.2 %	0.2 %
	不良品	0.5 %	68.1 %

4. 5 AIプラットフォーム

AIプラットフォームは、AIシステムの開発/監視/運用/保守を効率化し、AIシステムの価値を高めるために開発/運用している。構成図（図 25）に示す様に、AIプラットフォームは、国内外の工場に設置するAIシステム、AI拠点に設置する機能サーバ、それらを結ぶネットワークから構成される。機能サーバは、①AI開発（学習）、②監視、③運用保守、④データ活用/連携の 4 機能群から構成されており、ディープラーニング用スーパーコンピュータ (NVIDIA DGX-1, DGX-2) 上に実装している。AIプラットフォームにより、AI拠点から工場のAIシステムが遠隔制御でき、AIエンジニアをAI拠点に集約することで、コスト削減や迅速な対応も可能となっている。

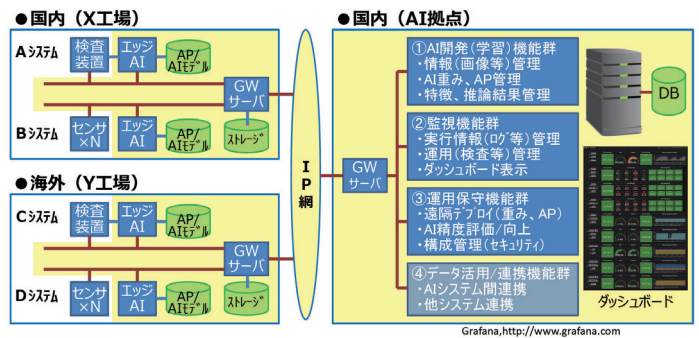


図25 AIプラットフォーム構成図

Fig. 25. Configuration diagram of AI platform.

4. 5. 1 運用時のAI精度評価/向上

AI精度を高めるには、発生しうるすべての情報を開発時点で用意したいが、現実的には極めて困難である。例えば運用開始後に、温度/湿度等の環境条件変化や、製造条件の揺らぎ（規格値内での微細な変化）発生、さらに 4 M (Man, Machine, Material, Method) 変更も生じ得る。

その結果、運用開始後に、学習不足や未学習による判定精度低下の懸念が生じる。この懸念に対して、運用開始後にサンプル抽出し、AIと人の判定を比較することで、AI精度を確認することが一般的である。ただしサンプル数を増やすと人の作業が増え、AIシステム導入効果が減少する。サンプル数を減らすと、AI精度低下の検出遅れ等のリスクが高まる（図26）。




図26 運用時のAI精度評価

Fig. 26. AI accuracy evaluation during operation.

この問題を解決するため、運用時のAI精度評価技術を開発した。本技術は、ディープラーニングのネットワーク構造や学習データが同一であっても、学習過程のランダム要素により生成される重みが微妙に異なり、判定精度や判定の得意不得意に差が生じることを利用している。特に、学習データが少ないクラス境界でこの差は発生しやすい。

本技術を、（図27）で説明する。3本の線は、重みの異なるAIにより、黄色い三角と、青い丸の領域を分割する線である。①は十分な学習がされている例である。3本の線はほぼ同様に領域を分割しており、判定に差が出ない。②は、重み毎に境界が異なり判定に差が生じる。そのため、③の黒い星印の判定結果は、重みにより異なる。

このとき、重みにより判定結果が異なるデータが、学習不十分データの候補となる。④では、候補データを精査し追加学習することで、判定の差が解消している。また、候補データ発生率は、AIの学習不足割合、即ち判定間違え率と相関するため、AI精度推定にも利用できる。




図27 重みの違いによる正解率の差

Fig. 27. Difference in accuracy due to different weights.

本技術を当社で開発したAIシステムに実装し運用している。運用期間の10%をサンプル抽出し人が判定した結果と、AI判定結果を比較することで、真のAI精度を算出した。同時にサンプル対象に本技術を適用しAI精度を推定したところ、高い相関（相関係数は0.93）が得られた（図28）。

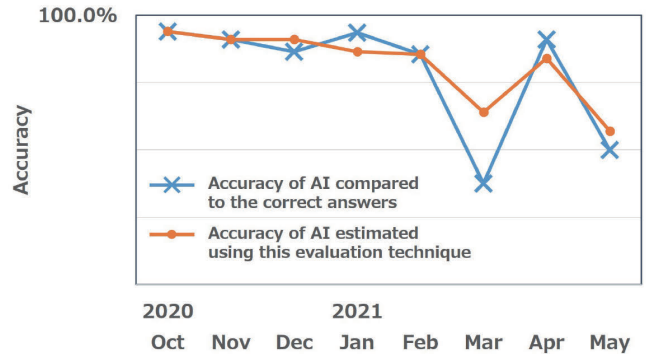


図28 運用時の精度評価結果

Fig. 28. Result of accuracy evaluation.

また、同期間の全検査に本技術を用いて学習不十分な候補を抽出したところ、70%の確率で実際に学習不十分であることが確認された。抽出した画像を（図29）に示す。

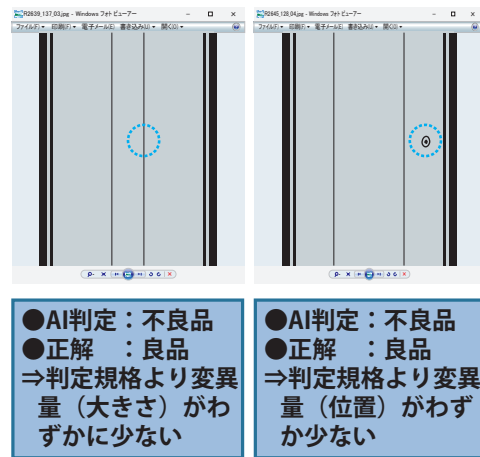


図29 本技術で抽出した画像の例

Fig. 29. Examples of images extracted by this technique.

5. ICT進化によるAIシステムアーキテクチャの変化

AI技術の進化と並行して、ICTも進化している。無線通信では5G導入が始まり、4GやWi-Fiより速度/低遅延/同時接続数が格段に向上している。また複雑なAIモデルを高速で処理するため、エッジAIもGPUを搭載するなど高性能化している。これらのICTの進化が、AIシステムアーキテクチャに変化をもたらしつつある。

（図30左）は、現状のAIシステムアーキテクチャである。問題点としては、エッジAIを製造レイヤに分散配置しており管理、保守、セキュリティ確保等がしにくいこと。また、環境条件（温度/湿度/電圧変動/振動/埃等）に課題が

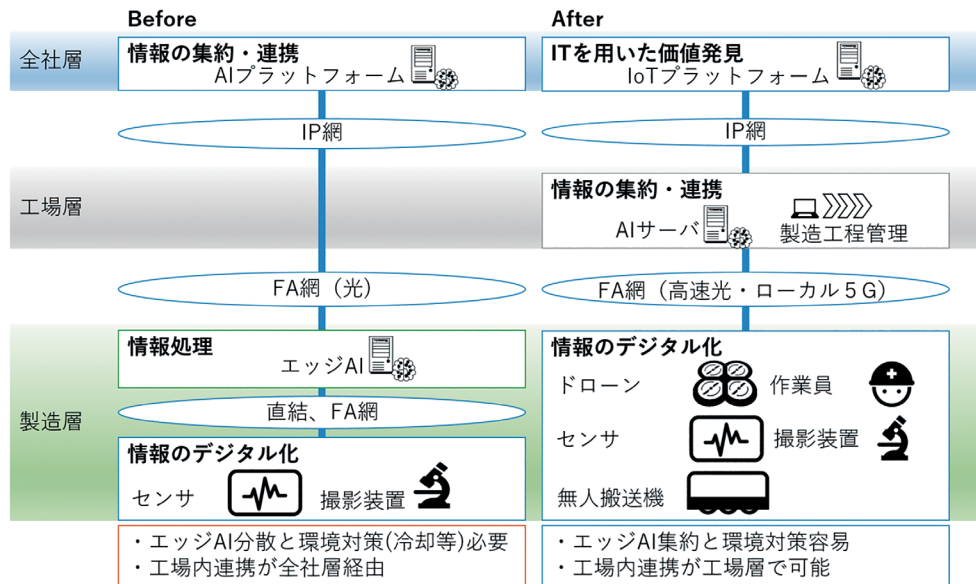


図30 ICTの進化によるAIシステムアーキテクチャの変化

Fig. 30. Changes in AI system architecture.

ある工場内に、発熱量が大きく高性能なエッジAIを設置するため、エッジAIを、高温/高湿度/振動/埃等から守るために空調ボックス内に設置したり、安定した電圧/電流を供給するためのUPSを設置するなど、環境対策が必要となることである。なお、AIモデルは毎年複雑化しており、エッジAIはさらに高性能化される方向であり、エッジAIのスペックは今後も高性能化される見込みである。

さらに、コンピュータを設置するレイヤについては、設置レイヤ数を多くすると異常時の切分け等が難しくなるため、現在は製造レイヤと全社レイヤにコンピュータを設置している。一方このアーキテクチャだと、工場内の連携処理は全社レイヤで実施する必要がある。無駄な通信や、信頼性低下をまねく懸念がある。例えばIP網の障害により、工場内の連携処理停止してしまう。

これらの問題の要因は、情報のデジタル化装置とエッジAI間の通信を高速/低遅延/高信頼にするために、直結かFA網（光）を用いざるを得ず、情報のデジタル化装置とエッジAIを分離しにくいからである。

ICTの進化によりFA網に産業用イーサネットなどによる低遅延化や、高速光化、5Gが導入されることで、現状の課題が解決可能となる。（図30右）は、今後のAIシ

ステムアーキテクチャの方向性である。通信技術の進化により、エッジAIは工場サーバに統合可能となり、管理がしやすくなるとともに、安定した環境条件のサーバ室で処理が実施できる。情報のデジタル化装置と工場サーバは、製造ライン構成の変更頻度や装置移動の有無等に応じて、高速光かローカル5Gで接続される。また通信の信頼性確保のため、高速光と5Gの両方を用いる場合も出てくる。さらに、コンピュータが設置されるレイヤは工場レイヤと全社レイヤとなり、工場内連携処理の実行も容易になる。

今後のICTやAIシステムアーキテクチャの進化に向けて、エッジAIと情報のデジタル化装置との疎結合化など、柔軟性/拡張性のあるシステム構築を進めていく。

6. むすび

本報告では、当社における製造工程へのAI適用について説明し、製造業においてもAIが実用化段階にあることを明らかにした。また、5G等によるアーキテクチャ進化も示した。今後は、AIシステム開発ロードマップに従い、AIが扱う情報の拡大と事業での適用領域の拡大に向け取り組みをさらに加速して行く。

参 考 文 献

- 1) Masahiro Kashiwagi, et. al. : “Approach to practical application of Deep Learning in manufacturer's production line” ,GPU Technology Conference 2017.
- 2) 黒澤公紀:「フジクラにおけるAI（深層学習）の取組と高出力半導体レーザウエハ外観検査への適用」, GTC-Japan, 2017.
- 3) Hiroyuki Kusaka, et. al. : “Practical Application of Deep Learning in Smart Factory : Visual Inspection System of Semiconductor Laser” , GTC-San Jose, 2018.
- 4) Hiroyuki Kusaka, et. al. : “High-accurate visual inspection for semiconductor lasers using Convolutional NeuralNetwork trained with original small dataset and additional synthesized images” ,IOT Enabling Sensing/Network/AI and Photonics Conference 2018.
- 5) Shinichi Nakatori, et. al. : “Automation of Inspection Process by AI (Deep learning)” , IoT-SNAP 2019.
- 6) 多田 和市 :「普通のAIと優秀なAIの連携プレー 半導体ウエハ外観検査を自動化」, 日経XTREND, 2018.
- 7) 日本ディープラーニング協会 : ディープラーニング活用の教科書—実践編, 日経BP 2018.
- 8) 日本ディープラーニング協会 : ディープラーニング活用の教科書—実践編, 日経BP, P.60, 2019.