

AIによる生産ラインの 生産性向上と自動化進展 ～第一弾：検査工程への取組み～

ファシリテータ

市本秀則；マツダ（株）

エディター

石田修一；ヤマザキマザック（株）、大北貴士；アビームコンサルティング（株）

メンバー

江田；三菱重工業（株）、角谷；富士ゼロックス（株）、久保田；（株）シーイーシー、
高木；（株）ニコン、高橋；（株）ウイルテック、巽；パナソニック（株）、
内藤；（株）ダイフク、浅野；（株）リコー、天沼；AAC（株）、
西村；中村留精密工業（株）、吉岡；YKK（株）、神保；日本電気（株）



Industrial
Value Chain
Initiative



3C01

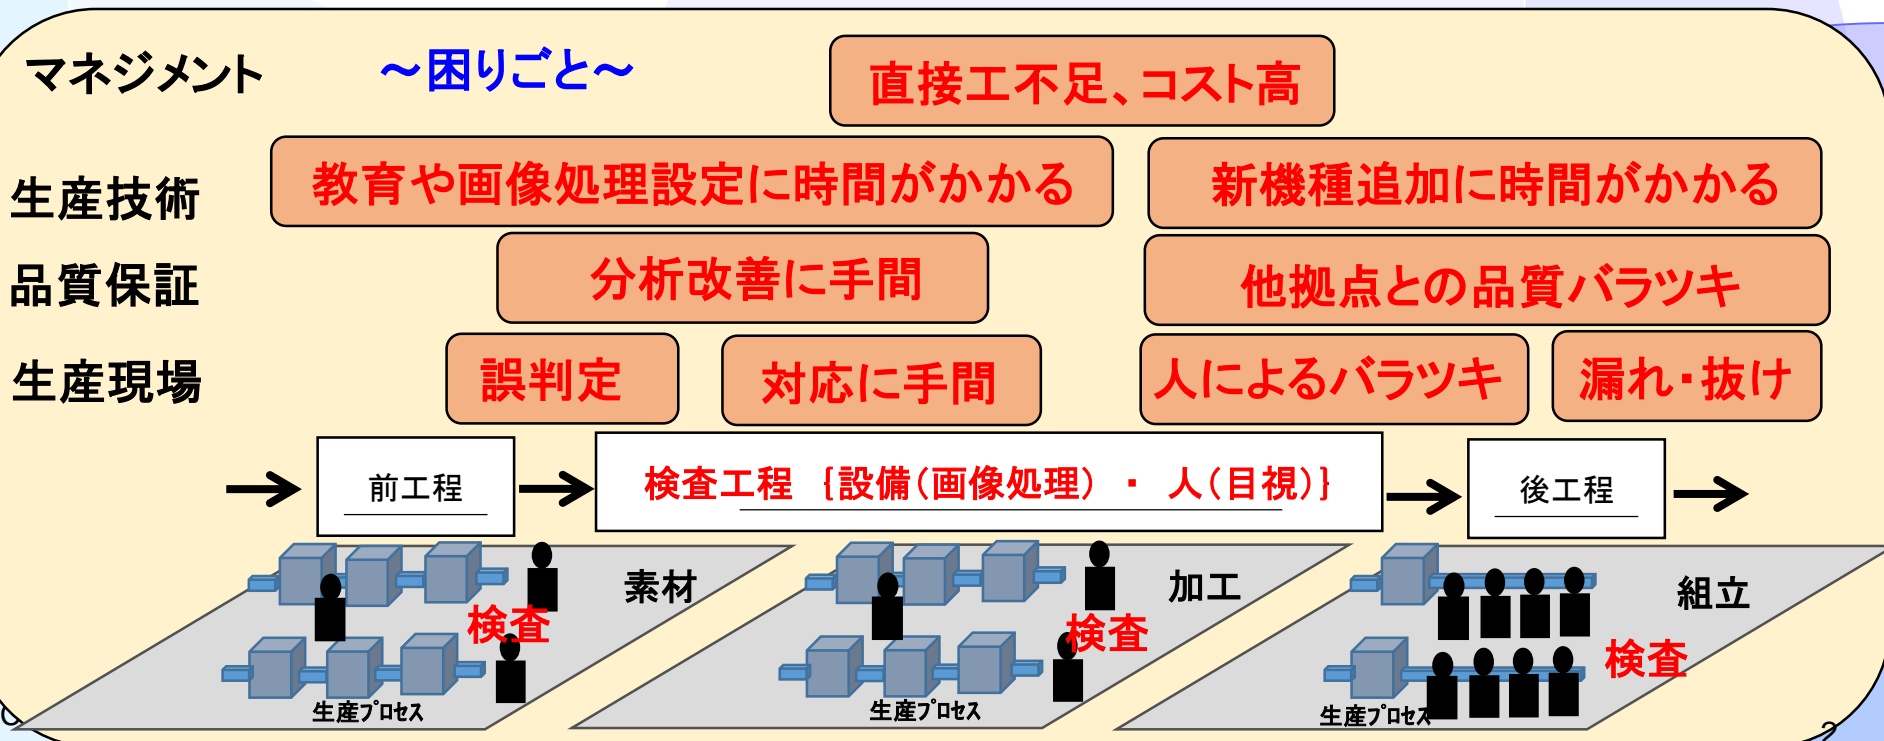
順不同、敬称略

(問題発見)

【現状と課題】

企業各社が働き方改革に取り組んでいる中で、生産ラインには、自動化できていない工程や自動化したものの人が手をかけている工程が存在している。生産ラインをAIの活用で知能化していくことでそれらの課題を解決し、生産性向上と自動化を進展させたい。

本WGでは、まずは、現状と知能化のあるべき姿を討議し、全体像を描く。その中から、順次AI導入を検討していく。その過程で、AIの勉強もしていく。第一弾として、各社困りごとが多かった検査工程へのAI活用に取り組む。



(問題記述 : AS-IS)

	量産準備	開始前～検査中 ～完了後
設備	設備 場面①	設備 場面②
人	人 場面①	人 場面②

• 設備 場面①

量産準備段階で、生産技術者が検査設備の設定を行う

生産現場

画像処理設定


検査装置

画像処理

カメラ

対象物

拠点ごとにパラメータを設定し、トライ&エラーを繰り返して決定する



生産技術者

生産技術 事前準備

対象物
サンプル画像

NG画像を収集し、NG部位以外をマスクし、対象画像を整理する

特徴抽出の
処理を設計

処理ロジック
を実装

NG項目ごとに特徴抽出処理を設定していき、画像処理装置に実装していく

困りごと

検査自動化に時間が掛かる

素材・加工・組立ラインの検査工程の画像処理パターン設定に時間が掛かり困っている

事前検証に時間が掛かり困っている

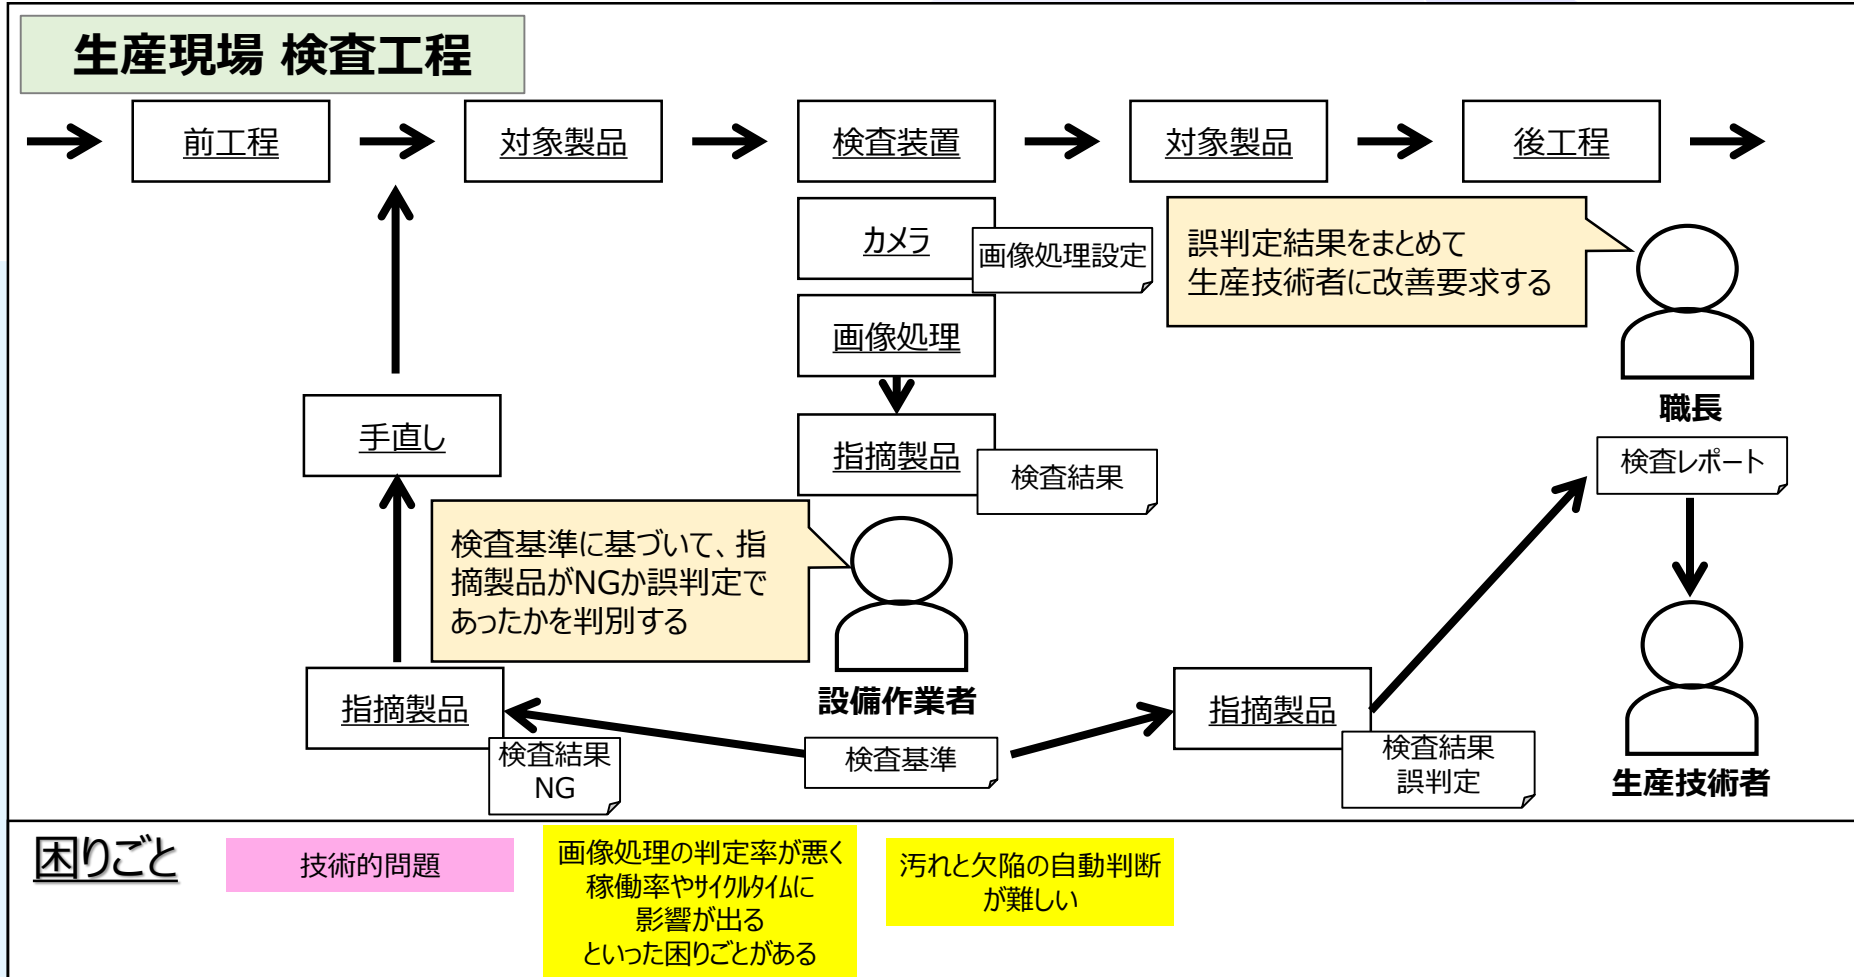
拠点ごとに設定や実装が必要

(問題記述：AS-IS)

	量産準備	開始前～検査中 ～完了後
設備	設備 場面①	設備 場面②
人	人 場面①	人 場面②

• 設備 場面②

検査中、測定結果を確認し、指摘製品をラインアウト＆修正する

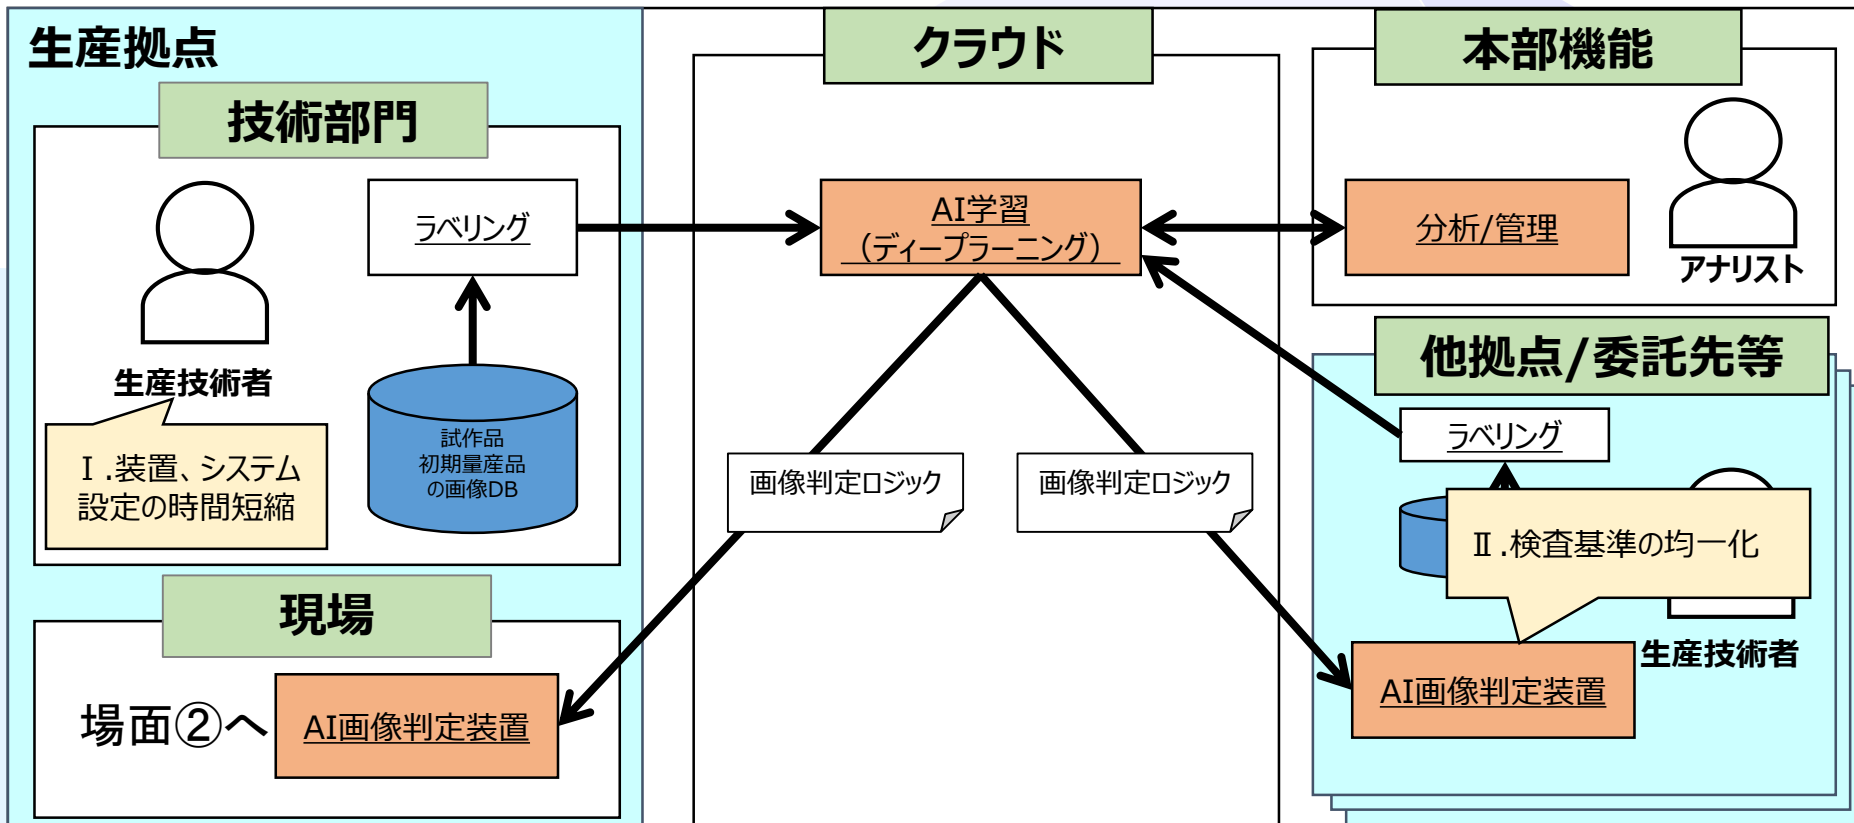


(課題設定：TO-BE)

	量産準備	開始前～検査中 ～完了後
設備	設備 場面①	設備 場面②
人	人 場面①	人 場面②

• 設備／人 場面①

量産準備段階で、AIの学習（ディープラーニング）を行う。判定ロジックのプログラミングが不要となる。同一のAIを拠点間で共有し、多拠点の検査基準が均一化される。



方針

I. 事前準備の簡素化、およびAI学習による特徴抽出、ロジック実装の自動化を実現する

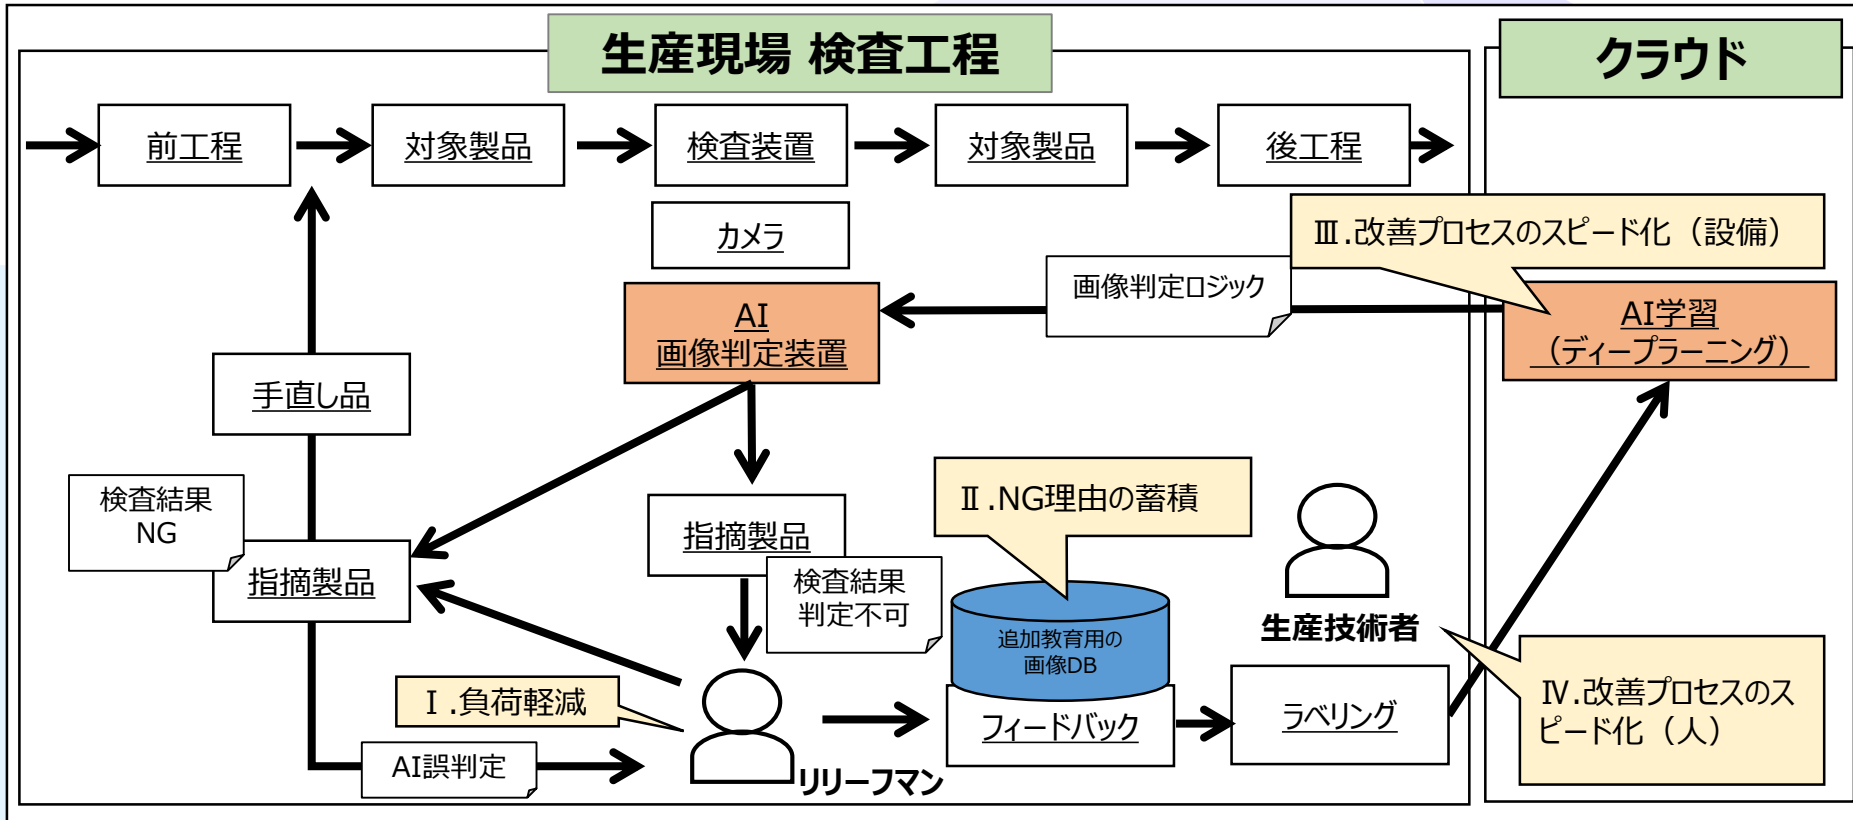
II. プラットフォーム化による検査基準の均一的な他拠点展開を実現する

(課題設定：TO-BE)

	量産準備	開始前～検査中 ～完了後
設備	設備 場面①	設備 場面②
人	人 場面①	人 場面②

• 設備／人 場面②

AIによる判定率の向上と、誤判定情報の素早いフィードバックが可能となる



方針

I. AIによる判定NGの信頼性の向上による負荷軽減を行う

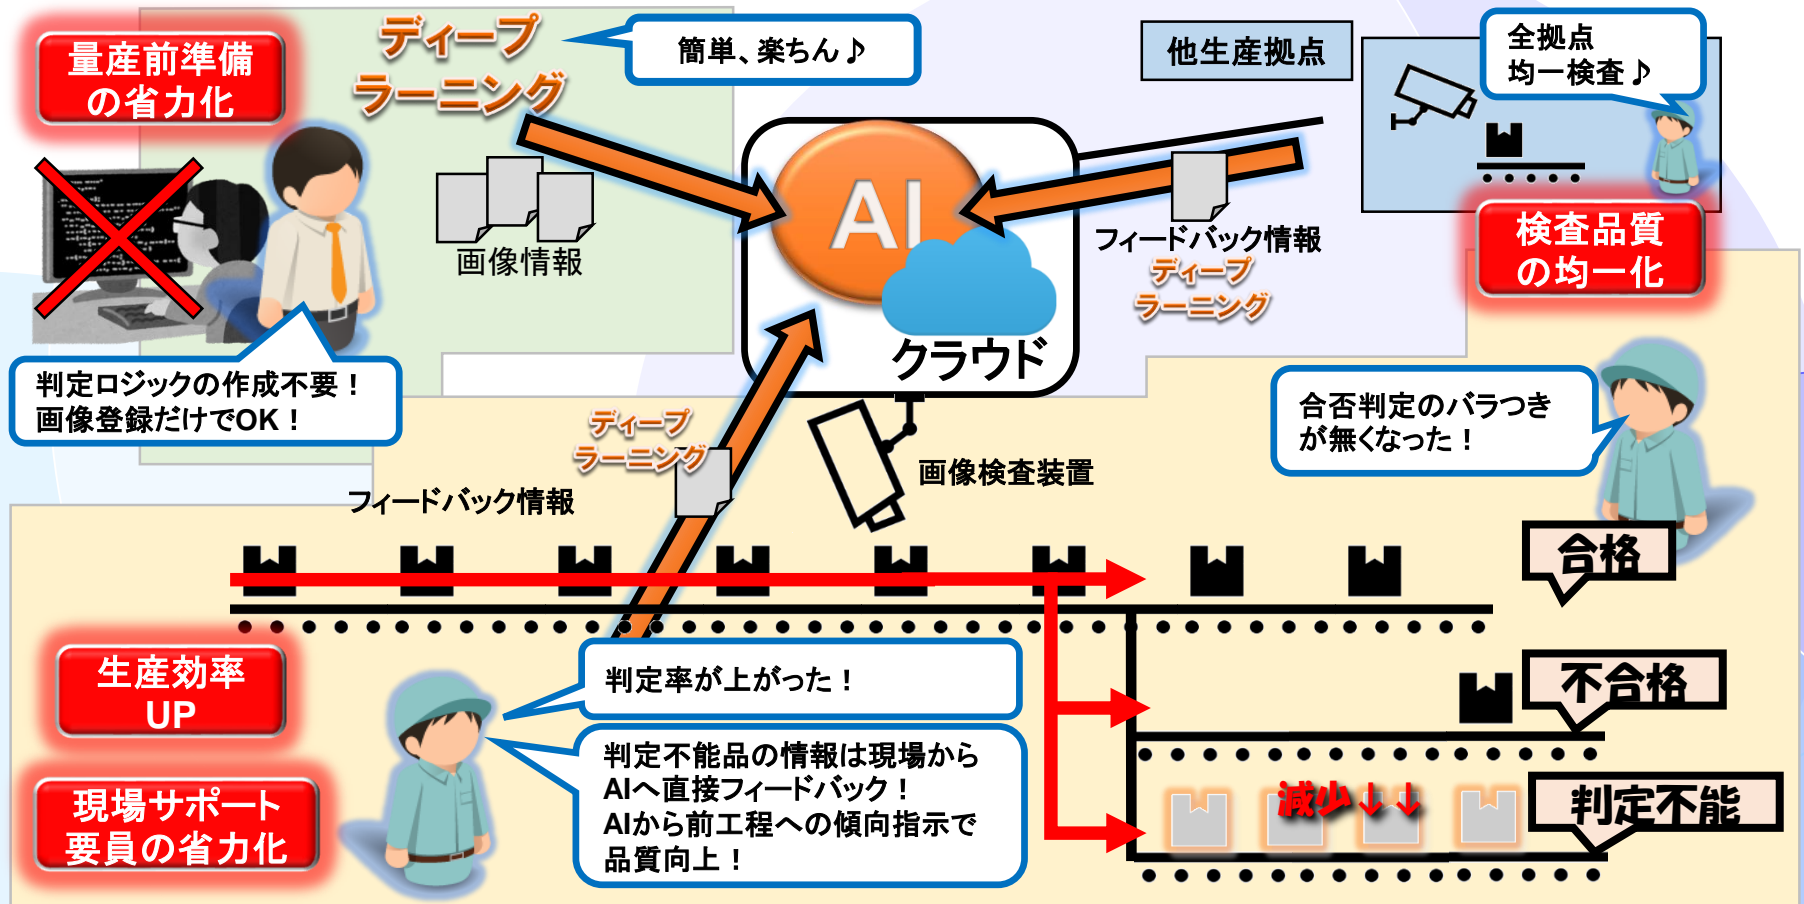
II. NG箇所の自動特定とデータ蓄積による原因分析を実現する

III. AI追加学習によるスピーディーな改善を行う

IV. 現場によるAI画像判定の改善実施を実現する

検査工程AI活用 目指す姿

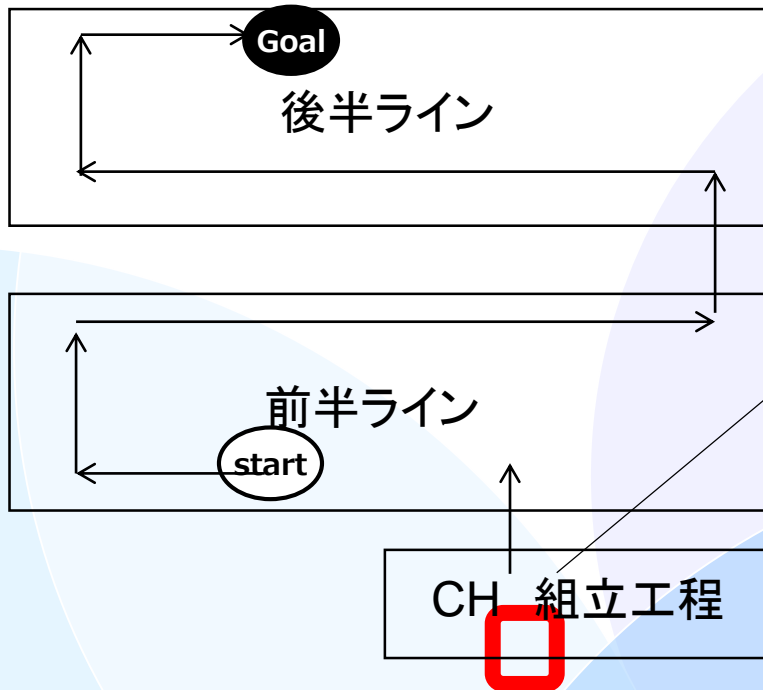
AIによる検査工程の効率化、自動化、品質向上




AS-IS / TO-BE ビデオ

■ 実証実験1 対象1 バルブスプリング組付け

マツダ株式会社 エンジン組立ライン



シリンダーヘッド組み付け工程



バルブスプリング手組付け



ロボット+カメラで撮像



組付け機種OK色判定

判定不能、機種追加時の手間大

単色
ピンク 水色 緑色 紫色 無色 ...

コンビネーション
黄色&黄緑色 ... 組忘れ 倒れ

■ 実証実験1 対象1 バルブスプリング DeepLearning

オンラインデータ取得(1月25日~30日)

イーサネット

PC (サーバー)
・種類毎 OK/NG ファイル

Deep Learning学習(2月1日~6日)

PC (サーバー)
・種類毎 OK/NG ファイル

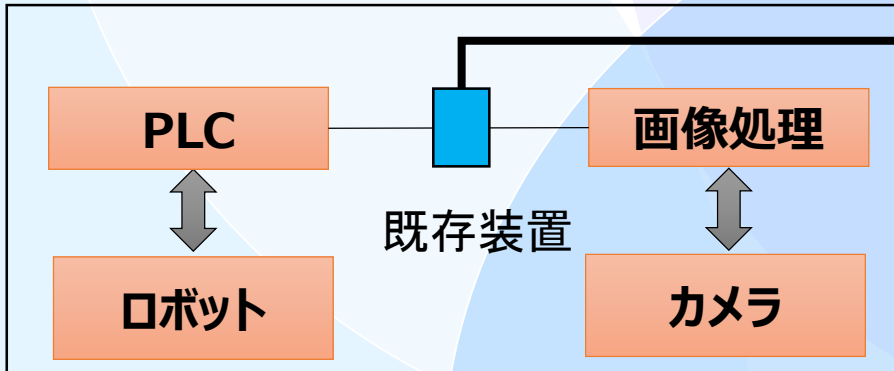

Deep Learning

オンラインDeep Learning判定(2月12日~)

イーサネット

PC (サーバー)

Deep Learning



具体的なシステム構成と検証項目

設備側

撮像装置
※既存検査設備も可



PLC等制御系

製造ライン等

WiseImaging

判別

検査クライアントPC




画像データ蓄積

**NVIDIA
GeForce GTX 1080**

追加学習

学習環境

Development Tool
(分類アルゴリズム作成ツール)



Learning Platform
(学習ツール)



- ・判定速度
- ・環境変化(照度、汚れ)への対応
- ・追加時の学習の容易さ

- ・画像蓄積データフォーマット
- ・前工程への情報提供内容
- ・追加学習時の情報内容

学習・検証の流れ

- 各クラスに枚数のばらつきがあり、
全画像を用いると学習・検証に時間が必要なため、
学習と評価のStepを2つに分け検証を実施した。

<Step1>

- ①各クラスから画像をN枚ランダムに抽出
- ②抽出した画像を学習用・テスト用にランダムで分類
- ③学習用画像を用いてWiseImagingにて学習
- ④テスト用画像を用いて精度を検証

<Step2>

- ⑤残りの画像を用いて精度検証
Step1では各クラスから20枚～900学習抽出。そのうち学習用画像として各クラスで10枚～450枚で実施
Step2ではデータセットの72,504枚のうち、Step1で使用した画像以外を用いて精度を検証

Step1 一部の画像を用いた学習・検証

■ 学習画像は各クラスよりランダムで抽出。4倍に増やし学習
学習枚数各10枚の場合、10枚×4×9クラス=360枚を学習
各クラスの精度は、学習枚数と同枚数を用いて計測

4倍)上下・左右・上下左右反転を画像処理で実行

<Wisemagingを用いた検証>

学習枚数	無色	青色	灰色	紫色	ピンク	緑色	黄緑色と ピンク	黄緑色と 紫色	黄緑色と 黄色	平均
各10枚	100%	100%	100%	100%	100%	100%	100%	100%	100%	100%
各75枚	100%	100%	100%	100%	100%	100%	100%	100%	100%	100%
各150枚	100%	100%	100%	100%	100%	100%	100%	100%	100%	100%
各300枚	100%	100%	100%	100%	100%	100%	100%	100%	99.67%	99.97%
各450枚	100%	100%	100%	100%	100%	100%	100%	100%	100%	100%

<一般的なCNNを用いた検証>

学習枚数	無色	青色	灰色	紫色	ピンク	緑色	黄緑色と ピンク	黄緑色と 紫色	黄緑色と 黄色	平均
各150枚	100%	100%	100%	100%	100%	100%	100%	100%	100%	100%

Step2 残りの全ての画像を用いて精度検証

Step1 不使用画像を用いて精度検証を実施(約63,500枚)

< WiselMagingを用いた場合 >

※「-」の箇所については、Step1で全て画像を使用したため、未実施

学習枚数	無色	青色	灰色	紫色	ピンク	緑色	黄緑色と ピンク	黄緑色と 紫色	黄緑色と 黄色	平均
各10枚	99.37%	100%	100%	100%	98.51%	99.95%	100%	100%	100%	99.77%
各75枚	99.98%	100%	100%	100%	97.83%	100%	100%	100%	100%	99.76%
各150枚	100%	100%	99.99%	100%	99.99%	100%	100%	100%	100%	99.98%
各300枚	100%	100%	100%	100%	99.96%	100%	100%	100%	99.62%	99.93%
各450枚	100%	100%	100%	100%	100%	100%	-	-	100%	100%

学習枚数が増えるにつれ、若干全体の精度が向上している。学習枚数が増えたことにより、学習結果(分類器)の汎用性が向上したと考えられる。

誤判定した内容を精査すると、単色を2色へ誤判定しているケースが多く、何も写っていない「無し」を「無色」「灰色」に誤判定しているケースが多い。

< 一般的なCNNを用いた場合 >

学習枚数	無色	青色	灰色	紫色	ピンク	緑色	黄緑色と ピンク	黄緑色と 紫色	黄緑色と 黄色	平均
各150枚	99.74%	99.99%	99.75%	100%	99.97%	99.9%	99.53%	100%	100%	99.88%

WiselMagingと比較した場合、平均精度差は0.1%だが、各クラスで誤判定している。画像のばらつきを学習しきれていないためだと考えられる。




■ 学習モデル作成時点でのまとめ

- 今回の学習では、画像間のばらつきが少なかった為、ネットワーク層数、学習パラメータ変化による優位性は無し
- ネットワーク構造による学習結果には差異あり。
- 枚数を増やした場合に精度が向上しているのは、枚数を増やしたことによりばらついた画像も学習出来た為。
- 学習時の画像にばらつきが少なかった為、色の濃さなどのばらつきのある画像の場合に、誤判定した可能性がある。
- 学習データの抽出をランダムではなく、人手でばらつきのある画像も含めて学習させることで汎用性も高まる。

実証実験1 対象2 鍛造クランクシャフト完成検査

マツダ株式会社 鍛造工場

材料供給



加熱&切断

ロール成形

鍛造プレス

矯正

冷却
ショットブラスト

レーザー刻印


完成測定

品質情報

- ・製造
- ・完成測定、不良

検査

欠肉(不良)




画像データを取得し、学習中

カメラ

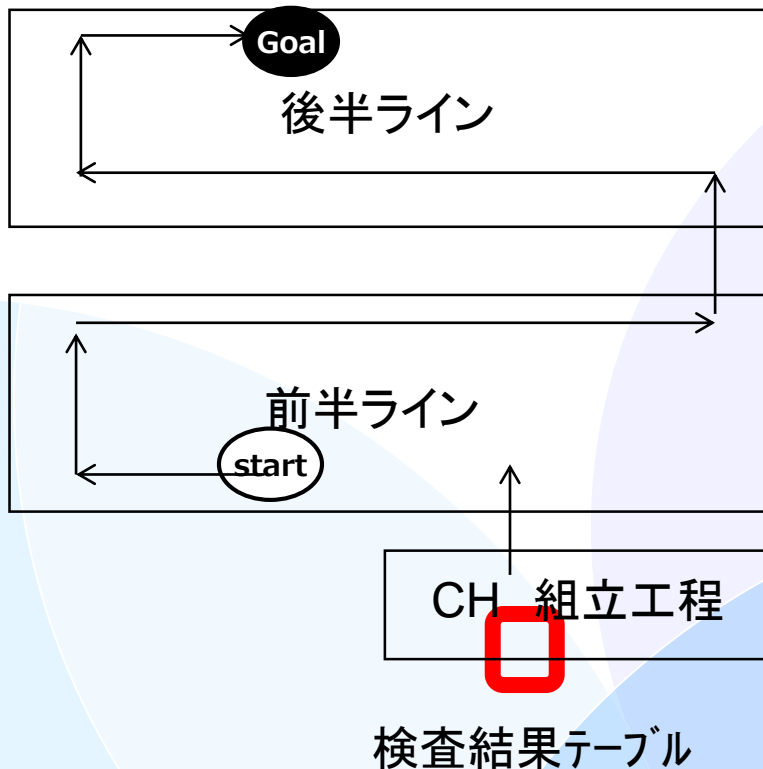
PC

データ



実証実験2 データ保存活用の実証

・バルブスプリング組付け



年月日時刻	生画像	ヒートマップ画像	判定結果
検査装置ID	#1 ... #16	#1 ... #16	#1 ... #16
エンジン製造NO			
撮影条件	...		
判定モデル			

データ活用実証(2月15日~28日)

疑似的に事務所で実証

Keep Data Hub




量産前準備の省力化



判定ロジックの作成不要！
画像登録だけでOK！

ディープラーニング

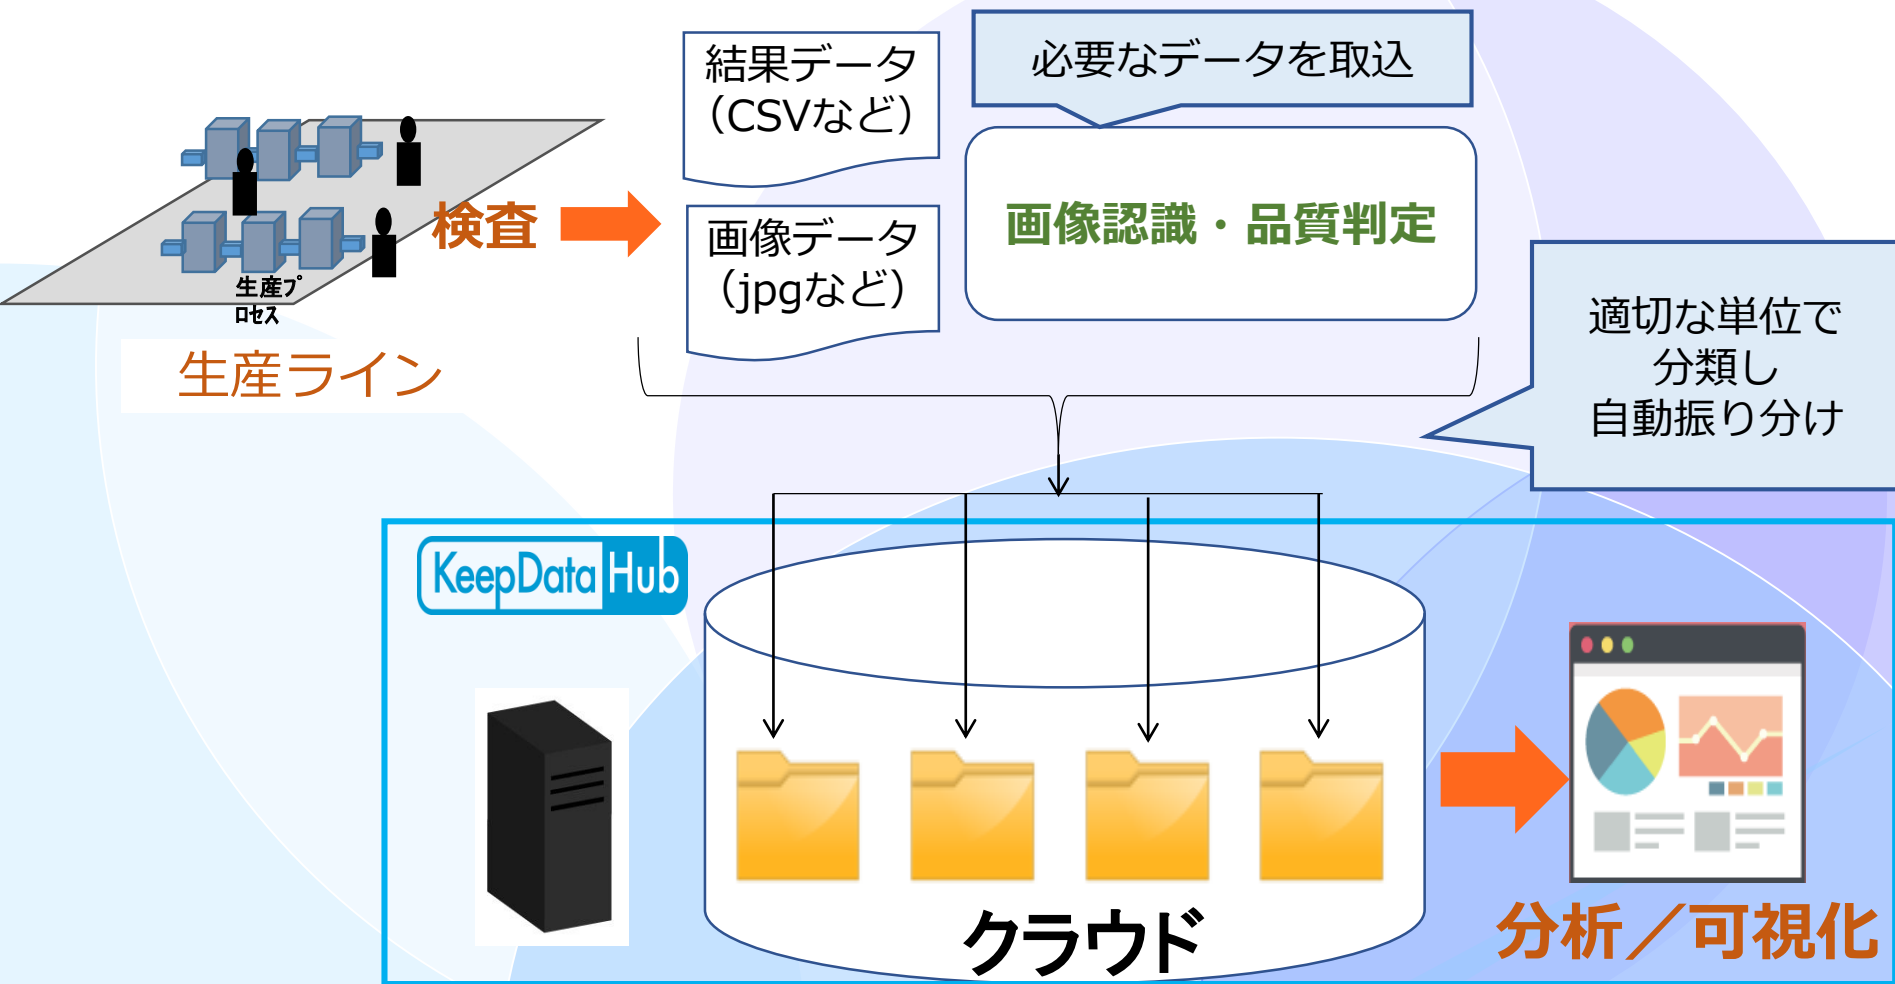
検証
高速・大容量処理が可能か



検査報告書
判定不能報告書

■ 実証実験2 データ保存活用の実証

- ・ 検査結果を画像と同時にデータベースに格納し、
即座に、多拠点で分析等有効活用できる方式を実証



考察：検査データの活用

- 検査データを活用することで、検査の自動化だけではなく前後工程の改善による生産性の向上も図ることができる。
- 検査NG発生時のデータから特徴を抽出し、改善につなげられる。
- 将来的には検査データの特徴抽出も自動化できると考える。

検査データの蓄積

- 自動検査実行時に、日時・ライン・AIバージョン・NG発生時の原因などをデータとして記録する



データモデル例

項目	説明	データ型	必須	更新
PK: Serial #	検査結果特定出力と一連のコード ※データが紐づくことができない	文字	必須	更新
検査モジュール	AI検査機内のソフトウェアの種類	文字	必須	AI
AI設定	AIの検査結果	合格品/不合格	文字	必須
理由	AIの検査理由	文字	必須	AI
エラーコード	不合格になった時のエラーを記録する	文字	必須	AI
AI検査日	AI検査を行った日	日付	必須	AI
検査員	検査員の名前、検査員が行った検査の種類	合格品/不合格 (合格-AI操作)	文字	A
検査結果	AIの検査結果	合格品/不合格	文字	A
不良品原因	不良品発生時の原因	原因...	文字	A
検査	不良品発生時の検査方法	検査/修理/廃棄/...	文字	A
検査員コメント	検査員からのコメント	文字	A	A
不良品原因	不良品発生時の原因、不良品の種類	原因/理由/...	文字	A
PK: 検査結果	検査結果	原因分析、量計に使用	文字	A
検査員	検査員の名前、検査員が行った検査の種類	検査員ID	文字	A
検査員コメント	検査員からのコメント	日付	文字	A

特徴の抽出

- 分析者は、検査データのうち、NGデータの日時や原因などから特徴を抽出する
- 将来的にはAIによる分析自動化も検討する

- ✓ 毎週、金曜日の15時ごろにNGデータが多く発生しているな
- ✓ ○月○日からNGデータが発生し始めているな



NG分析



改善への活用

- 特徴の内容から改善を実施する

✓ ○月○日からNGデータが発生し始めているな

✓ この日から新人がラインに入っているな。再教育が必要だな。



■ 今後の展望

- AIによる検査工程の自動化を実現する際は、各社の状況に応じて検討するポイントはあるものの、検査精度や生産性の向上に寄与する技術であると考える。
- WG内でも各社の状況に応じて、本技術を追いかけていく予定。

検討ポイント

- ✓ Deep Learningによる画像検査の得手 / 不得手の判断
- ✓ 学習データの取得・管理方法
- ✓ 検査データの活用方法

期待される効果

- ✓ 検査精度の向上
- ✓ 自動化による人的資源の補完
- ✓ 前後工程へのFBによる生産性の向上

WGメンバーの声

- ✓ 条件を限定すれば、AIは実用レベルであると認識できた。
- ✓ 学習データが40～50枚程度の画像でもある程度の精度が出ることは驚き。一方で、試作・開発段階からNG画像を含めた学習データの収集や大量画像のマネジメントが重要と感じる。
- ✓ 規格化が難しい官能検査や設備保全に応用したい。
- ✓ Deep Learningによる画像検査の得手 / 不得手が理解できた。まだまだ技術の進歩も必要だが、基本は人の目の代替として活用できると感じた。
- ✓ Deep Learningだけではなく、他のAI技術の検証も実施してみたい。

Special Thanks

- 実証実験協力 (IVIメンバー以外)

株式会社シーイーシー 大和田様

日本電気株式会社 矢田様、川元様

Keepdata株式会社 石澤様、藤本様

■ 終わりに

次は、間接領域
のAIをやりたい。

AIで熟練工の
ノウハウを取り
込みたい。

AIで加工を
最適化したい。

**早くも今後に向けて語り合う！
次回も乞うご期待！
1年間ありがとうございました！！**

IVI_WGに参加して良かった！！