

事業者視点における 目視検査自動化の理想と現実

モノづくりの進化と革新を支える



取締役CTO 伊藤 桂一

自己紹介 伊藤 桂一



学生時代は、産業技術総合研究所で卒業研究。
その縁で、AIST認定ベンチャーに入社。
その後、**20年間AIの研究開発**に従事。

主に取り組んだ研究開発事例

- ・ GAによる光学機器の自動調整、半導体設計の最適化
- ・ 動画/静止画/センサ/音の異常検知

2012年 弊社創業と同時に入社

2014年 現職

アウトライン

1. 目視検査自動化について
2. アダコテックの検査自動化技術
3. 事業者視点の理想と現実3選
4. まとめ



目視検査自動化について



単調

プレッシャー

熟練が必要

検査を取り巻く社会問題

検査工程の就業者数

140万人



工場従事者の
5人に1人

圧倒的な人不足

2020年7月2日 日本経済新聞 朝刊

2017年以降、相次ぎに発生した完成車の検査不正。このほど日産自動車、SUBARU（スバル）、スズキの3社の再発防止策が出そろった。検査員を従来の1.9倍に増やしたほか、適切な検査データを洗い出すシステムなども導入した。3社の投資総額は5000億円に及ぶ。工場の自動化への信頼をこじらせたため、実効性が問われる。スズキは6月初めに国へ通告に対し、完成車検査不正の再発防止策60項目を全て実施し報告した。鈴木俊宏は「様々な対策を講

車3社、再発防止へ対策

検査員1.9倍 投資5000億円

完成車の検査不正の再発防止策

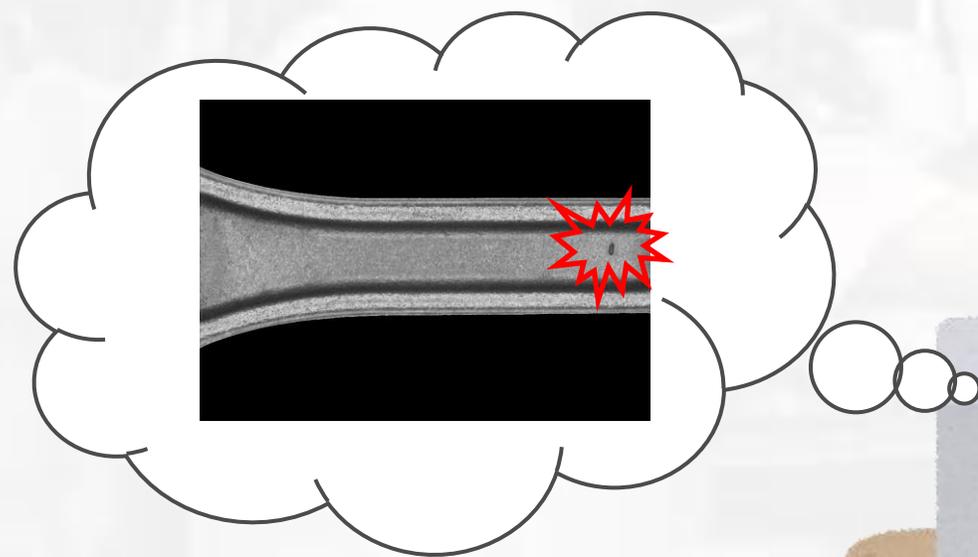
日産	・検査員を2.5倍の850人 ・不適切なデータの監視システム導入
	・検査員を2割増の450人

じ、ようやく正常な能力を保てるようになった」と語る。4月24日は日産が93項目、スズキが65項目を実施したと報告済みで、各社の対策が出そろったことにならぬ。不正発覚の発端は9月。日産の追浜工場

完成車の検査不正問題

検査に適用する際の大きな課題

不良品の見逃し0%という意味で100%に近い性能が求められる



不良品は絶対
見逃せない！！

検査の自動化は2つの熟練を要する

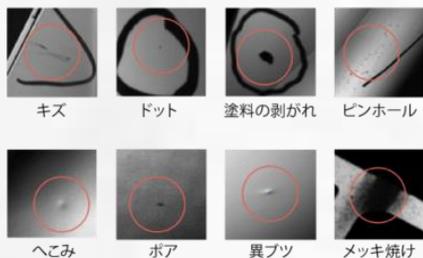


外観検査自動化における課題(お客様の声)

ルールベース

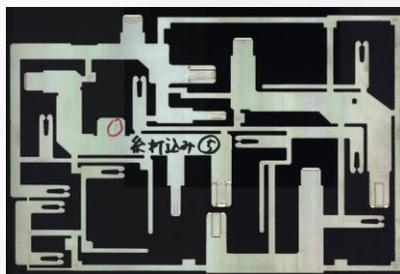
設定が複雑で
手間がかかる

都度ルールを
作るのが大変



想定外の異常に
対応できない

欠陥がどこに発生
するかわからない



Deep Learning

膨大な数の不良品
データが必要

不良品率は0.1%以下
データ収集だけで
数か月かかることも



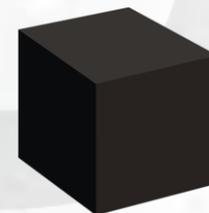
高価なPCが必要

膨大なデータを
処理するため、
高性能PCが必要



判断根拠が
ブラックボックス

異常判定の根拠が
わからず、
導入のハードルに



これらの課題を解決するための色々な取り組みがなされている。

AI Quest

AIプロダクト品質保証ガイドラインの策定

などなど

検査自動化を現実するための取り組みは多くある

事業者視点における
技術観点での
目視検査自動化の理想と現実

アダコテックの検査自動化技術

事業者視点で目指すべき事

目視検査自動化ソリューションの提供で事業をスケールさせる



スタートアップの場合、
ユニコーン企業とか
第2の〇〇とか
になる事が求められる

弊社設立時に考えていたこと

高い検査精度を実現
できる技術を確立すれば
成功間違いなし！！



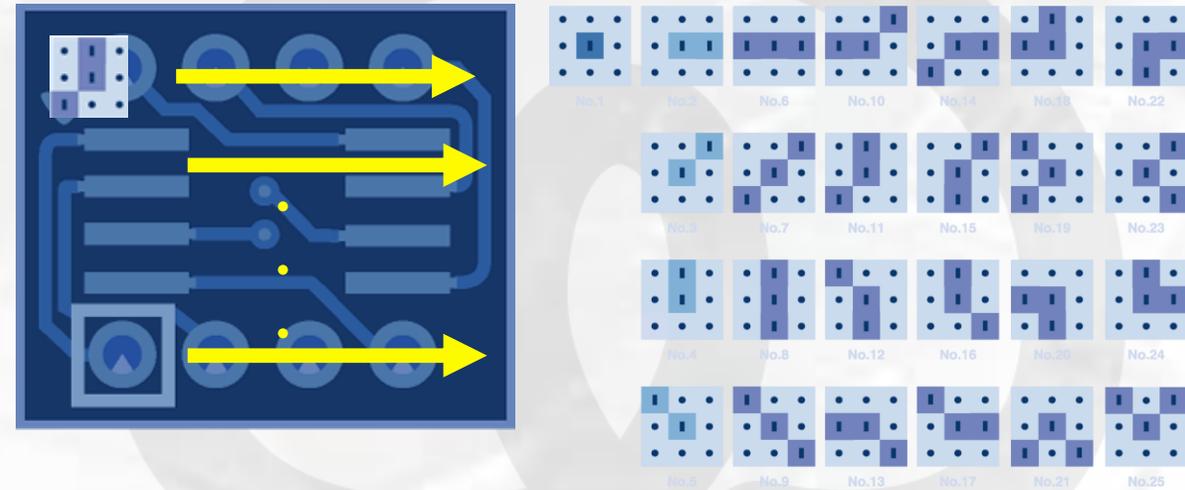
AISTのHLACを活用した技術により実現を目指している

HLAC特徴量とは？

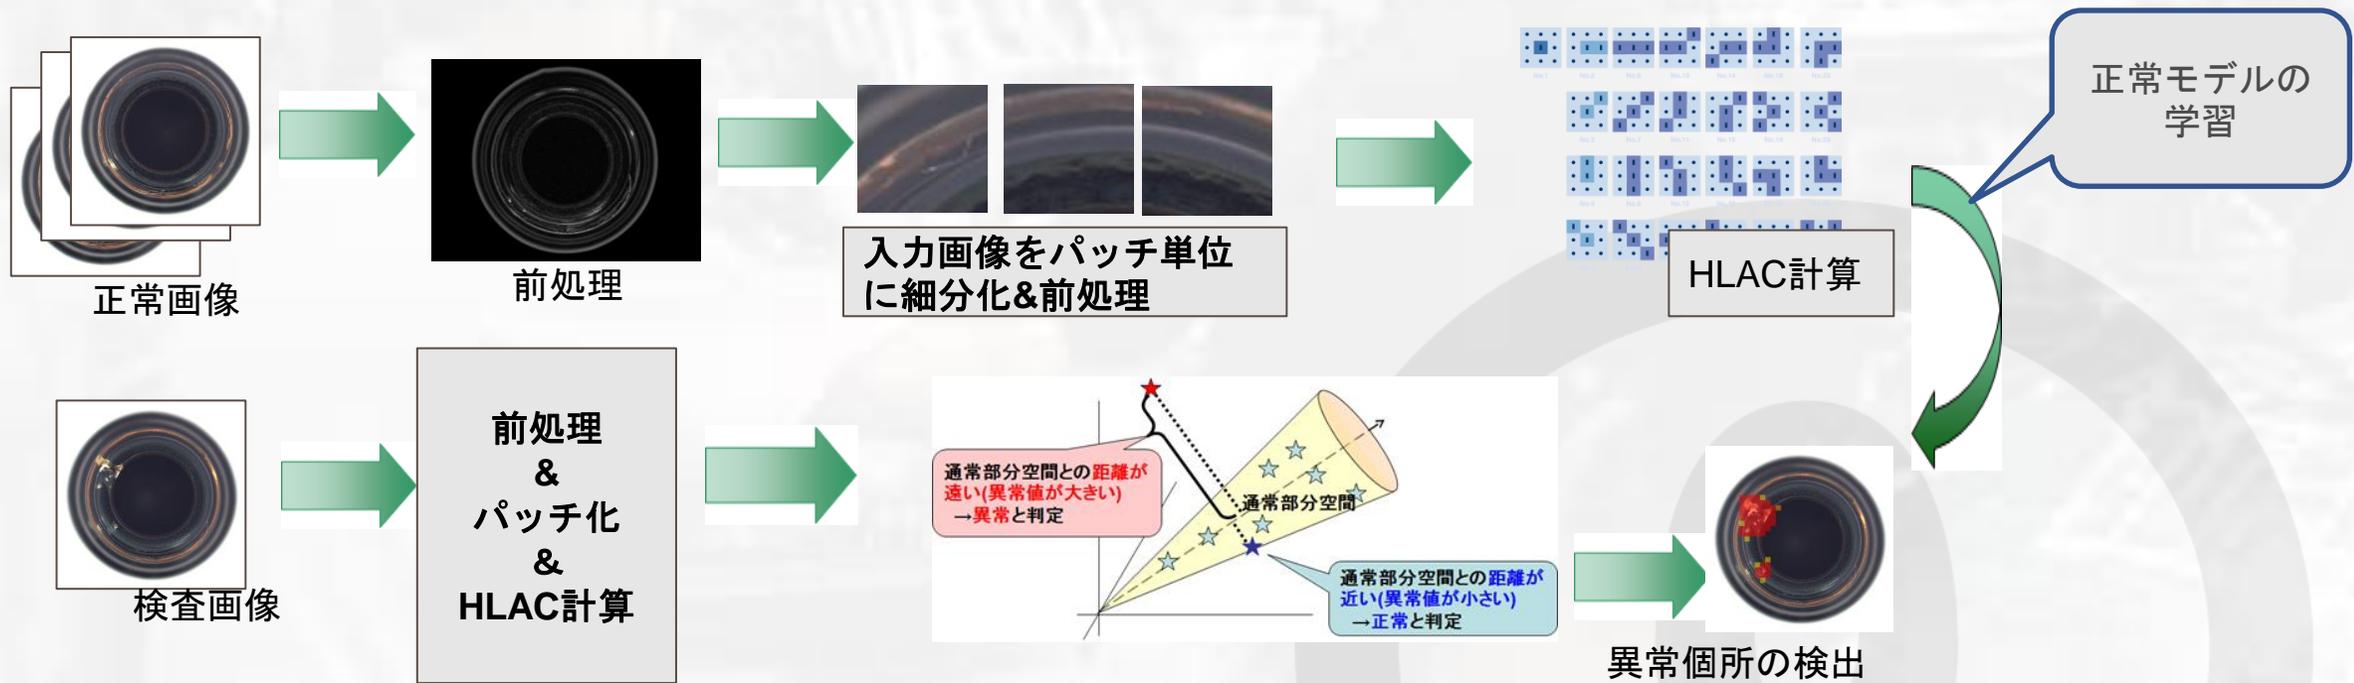
画像の特徴を認識する 産総研の技術

- ピクセル間の相関から形状や面積等の情報を瞬時に計算
- 加法性等パターン認識に好ましい特性を持つ

$$x(a_1, \dots, a_N) = \int f(r)f(r + a_1) \cdot \dots \cdot f(r + a_N)dr$$



HLAC検査処理の全体イメージを説明



- 良質な特徴量により、シンプルな手法で高い精度を実現
- GPUを活用しなくても高速処理が可能で、チューニングなどのトライ&エラーが容易

弊社の実績

- 2018/07/17 三井E&Sマシナリ様 トンネル検査への導入
- 2019/02/05 三井E&Sエンジニアリング様 溶融スラグ監視への導入
- 2020/06/04 セントラル警備保障様事例
- 2021/03/29 相川プレス工業様 平バスバー検査の自動化

その他大手メーカー様との導入推進中

事業化視点の理想と現実3選

理想と現実1：汎用性への過度な期待

AIは汎用的な技術で、自動車、半導体、食品、医療と様々な分野に展開していける！



理想と現実1：AIはシステム全体の一部でしかない

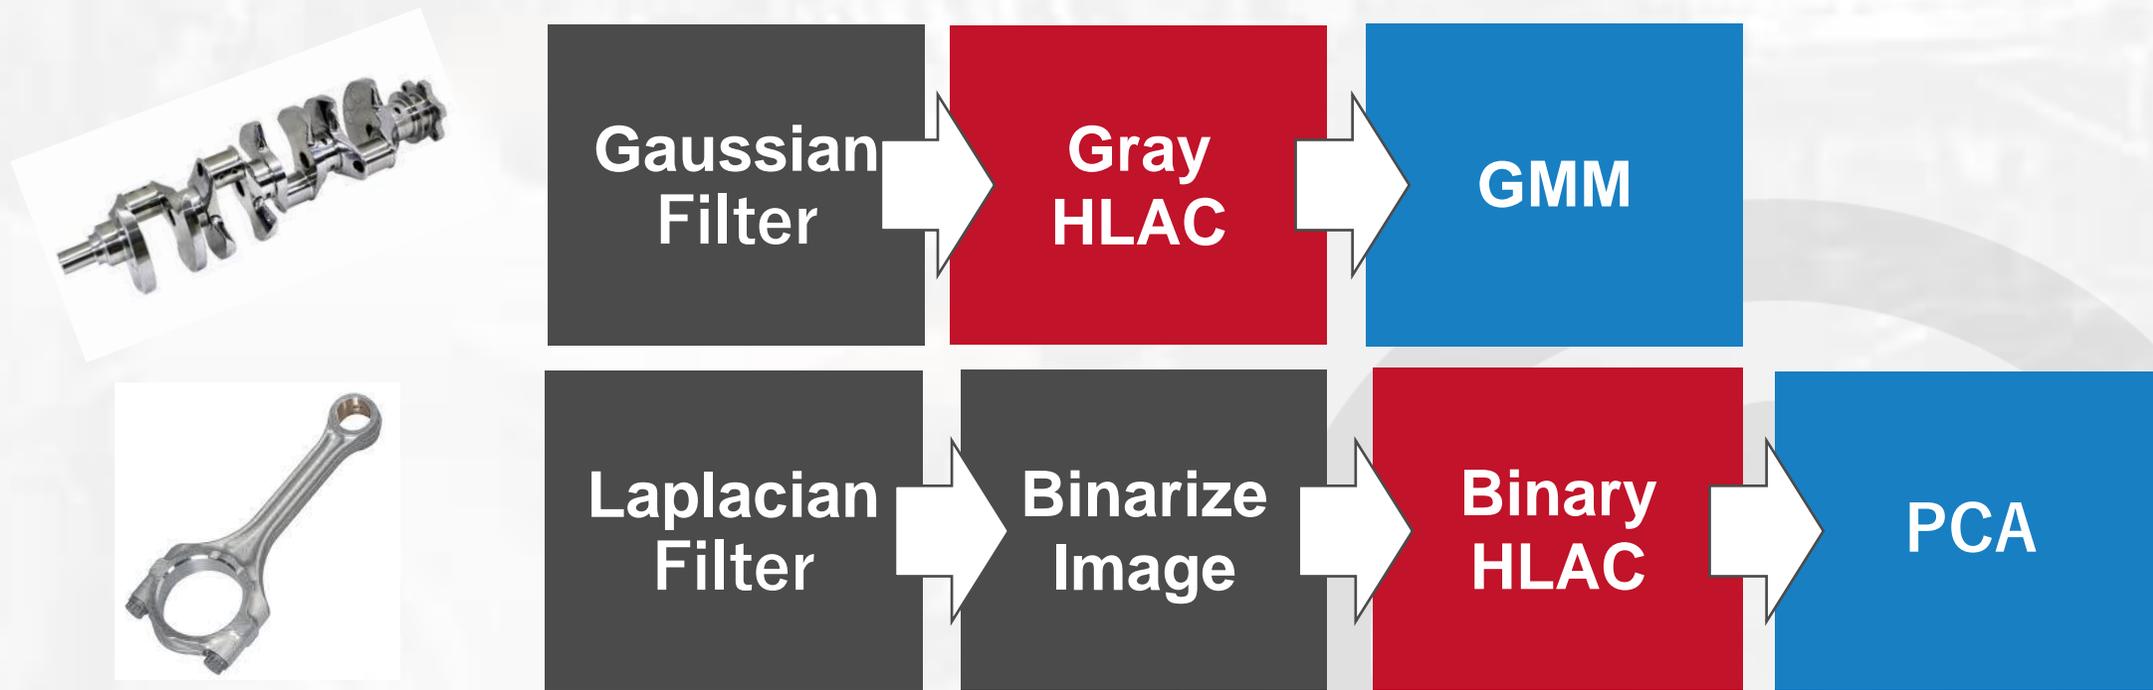
検査システム全体で考えた場合、検査対象ごとに個別対応が必要となるケースが多々存在する。

検査アルゴリズム単体で見ても、検査対象ごとの特性を見てアルゴリズムを変更する必要がある。

- ・ ルールベースの組み合わせ
- ・ 特定欠陥検出用のAIモデルを追加する

**ノウハウの横展開ができず開発工数が増大し
受託開発を繰り返す形になってしまう**

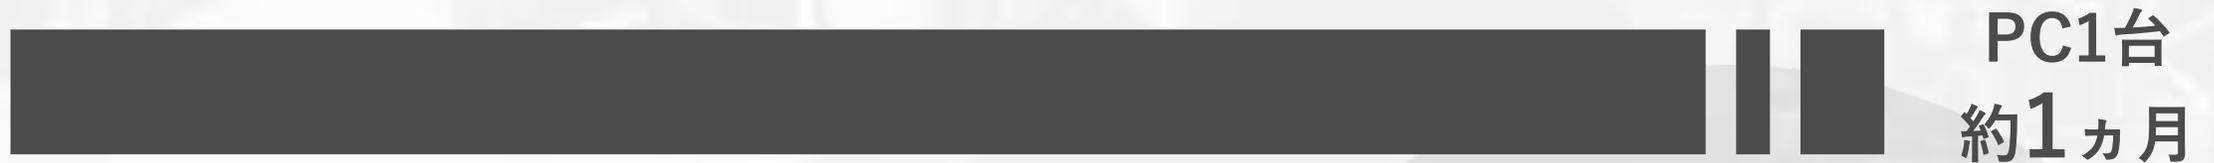
理想と現実1：検査アルゴリズム自動生成による工数削減



「プログラム開発」と「**パラメータ調整**」を自動化

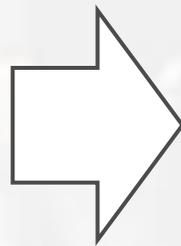
理想と現実1：グリッドサーチを効率的に活用していく

10万パターンのパラメータ総当たりに要した時間



理想と現実1：AIイネーブルメントの実現

熟練エンジニア
1週間



AI初心者
0.5時間

誰もが短時間で検査モデルを作成する事が可能

理想と現実2：新機能のリリース

新機能が開発できた！
これをリリースすれば
売り上げ倍増だ！



理想と現実2：誰も使ってくれない

「新機能」＝「お客様が必要な物」ではない
必要なものでも、**お客様が**使いこなせなければ使われない
プロダクトアウトで開発していくと、さらに混乱に拍車がかかる。

**無駄な開発投資で誰も利用しないものが
開発されてしまう。**

理想と現実2：オペレーションをプロダクトに

3つのステップでユーザーが求める機能をリリースする



理想と現実2：検査アルゴリズム自動生成の場合

3つのステップでユーザーが求める機能をリリースする



熟練のAI技術者が
検査アルゴリズム
を開発する

探索範囲の決め方
評価指標の選定
性能悪い時の対策

プロダクトとして
リリース

理想と現実3：運用開始できればお終い

無事に運用開始！
後は横展開
を待つだけだ！



理想と現実3：運用開始がスタート

年に2回くらいは何だかんだで相談を受ける。

- ⇒ 原材料の仕入れ先が変わったら誤報が頻発
- ⇒ 設備側の摩耗で誤報が頻発
- ⇒ レンズが汚れていく
- ⇒ 不良が見つけれない死角があった

リリース後の対応も当然考慮する必要がある

理想と現実3：導入後にこそHLACの強みがある



- ・再学習が短時間で行える。
- ・ケースによってインクリメンタル学習の活用も可能
- ・モデルの特性が把握しやすく、追加処理の導入が容易

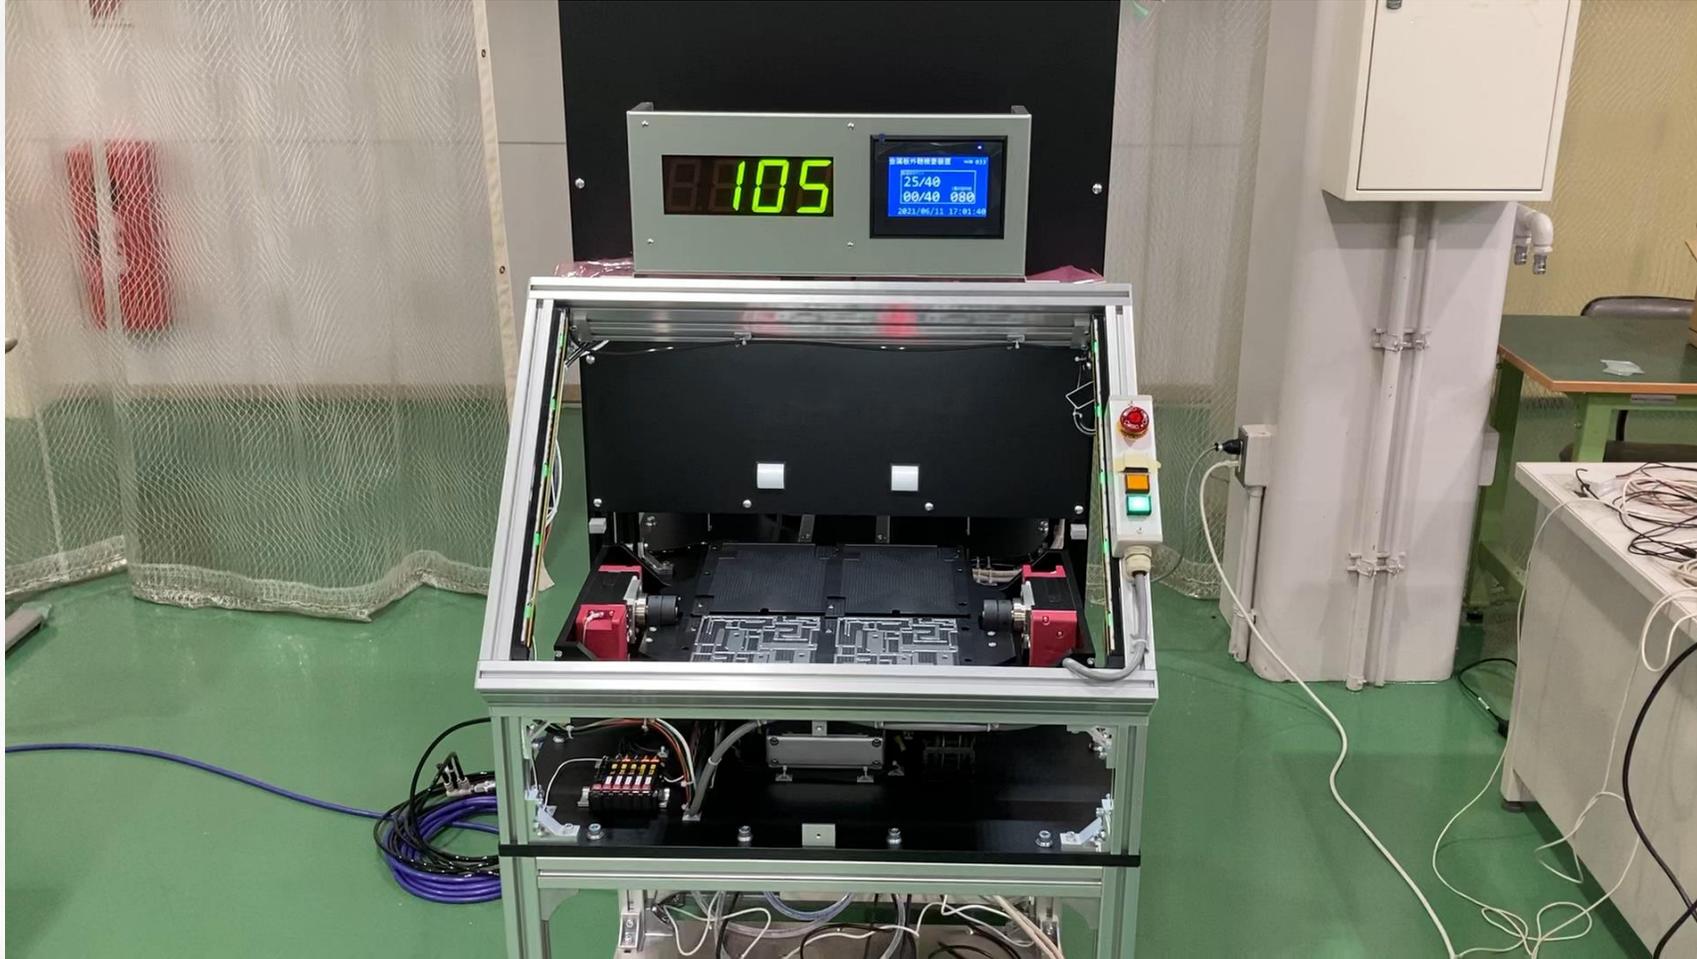
ベンダー側のうれしさ

- ・サポート工数が低減できる

ユーザー側のうれしさ

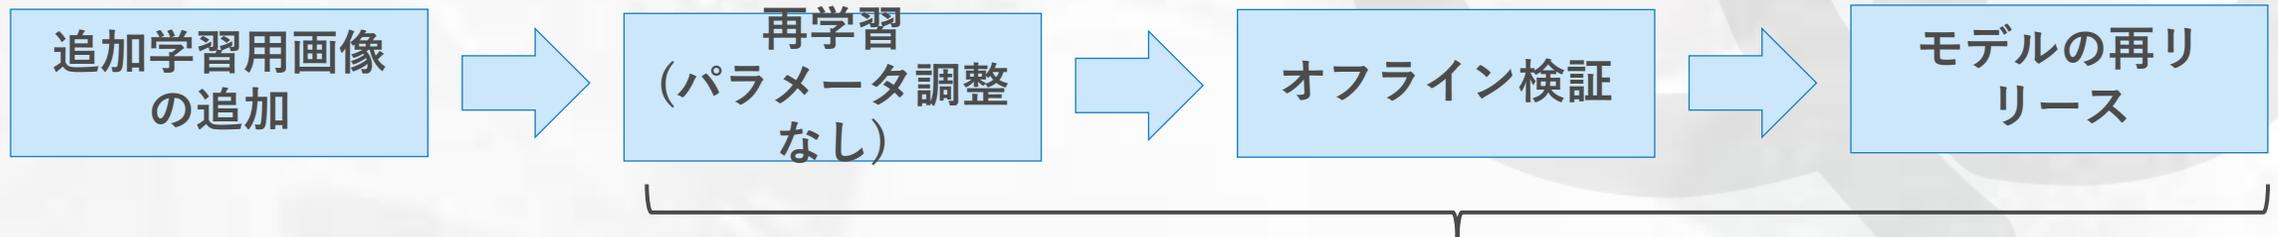
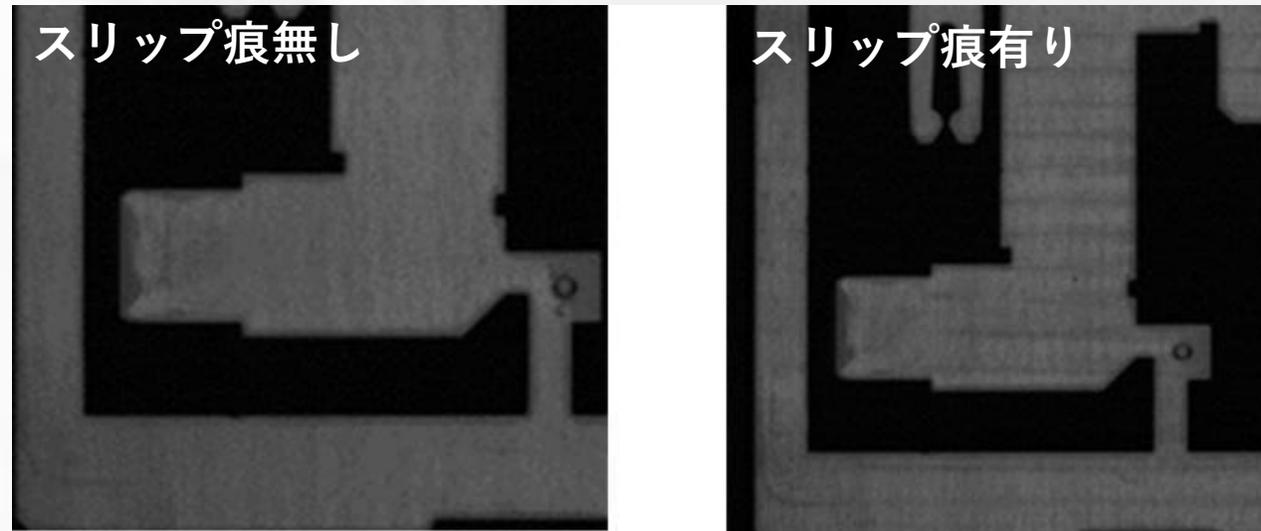
- ・生産ラインに停止時間を最小化できる ⇒ 機会損失の抑制

理想と現実3：モデルのメンテナンス事例紹介



理想と現実3：モデルのメンテナンス事例紹介

運用開始後、周辺設備の状態によりワークにスリップ痕が生じ誤報率が50.0%まで悪化しモデルの更新を行った事例



まとめ

世の中には、HLACをはじめとした多くの素晴らしい異常検知技術が開発されているが、性能だけでベンダーが選ばれる事はほぼない

事業者としてAIを提供する場合、ユーザビリティや運用後のオペレーションを意識したプロダクトの提供が必須

泥臭さを厭わない強い気持ちが重要