



AI導入ガイドブック

外観検査(部品、不良品あり)

2021年3月発行

本ガイドブックの対象者および目指すこと(1/2)

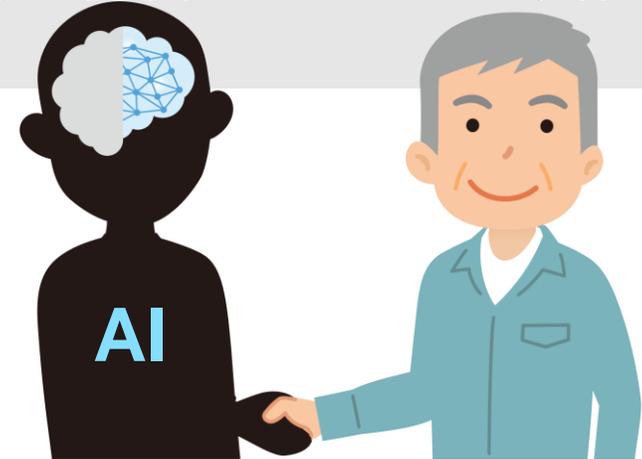
部品¹を製造する製造業で、検査業務に
お困りのあなたに・・・



このガイドブックを読めば、自社主導での
AI導入方法が分かります!!

特に以下の条件に当てはまる方向け

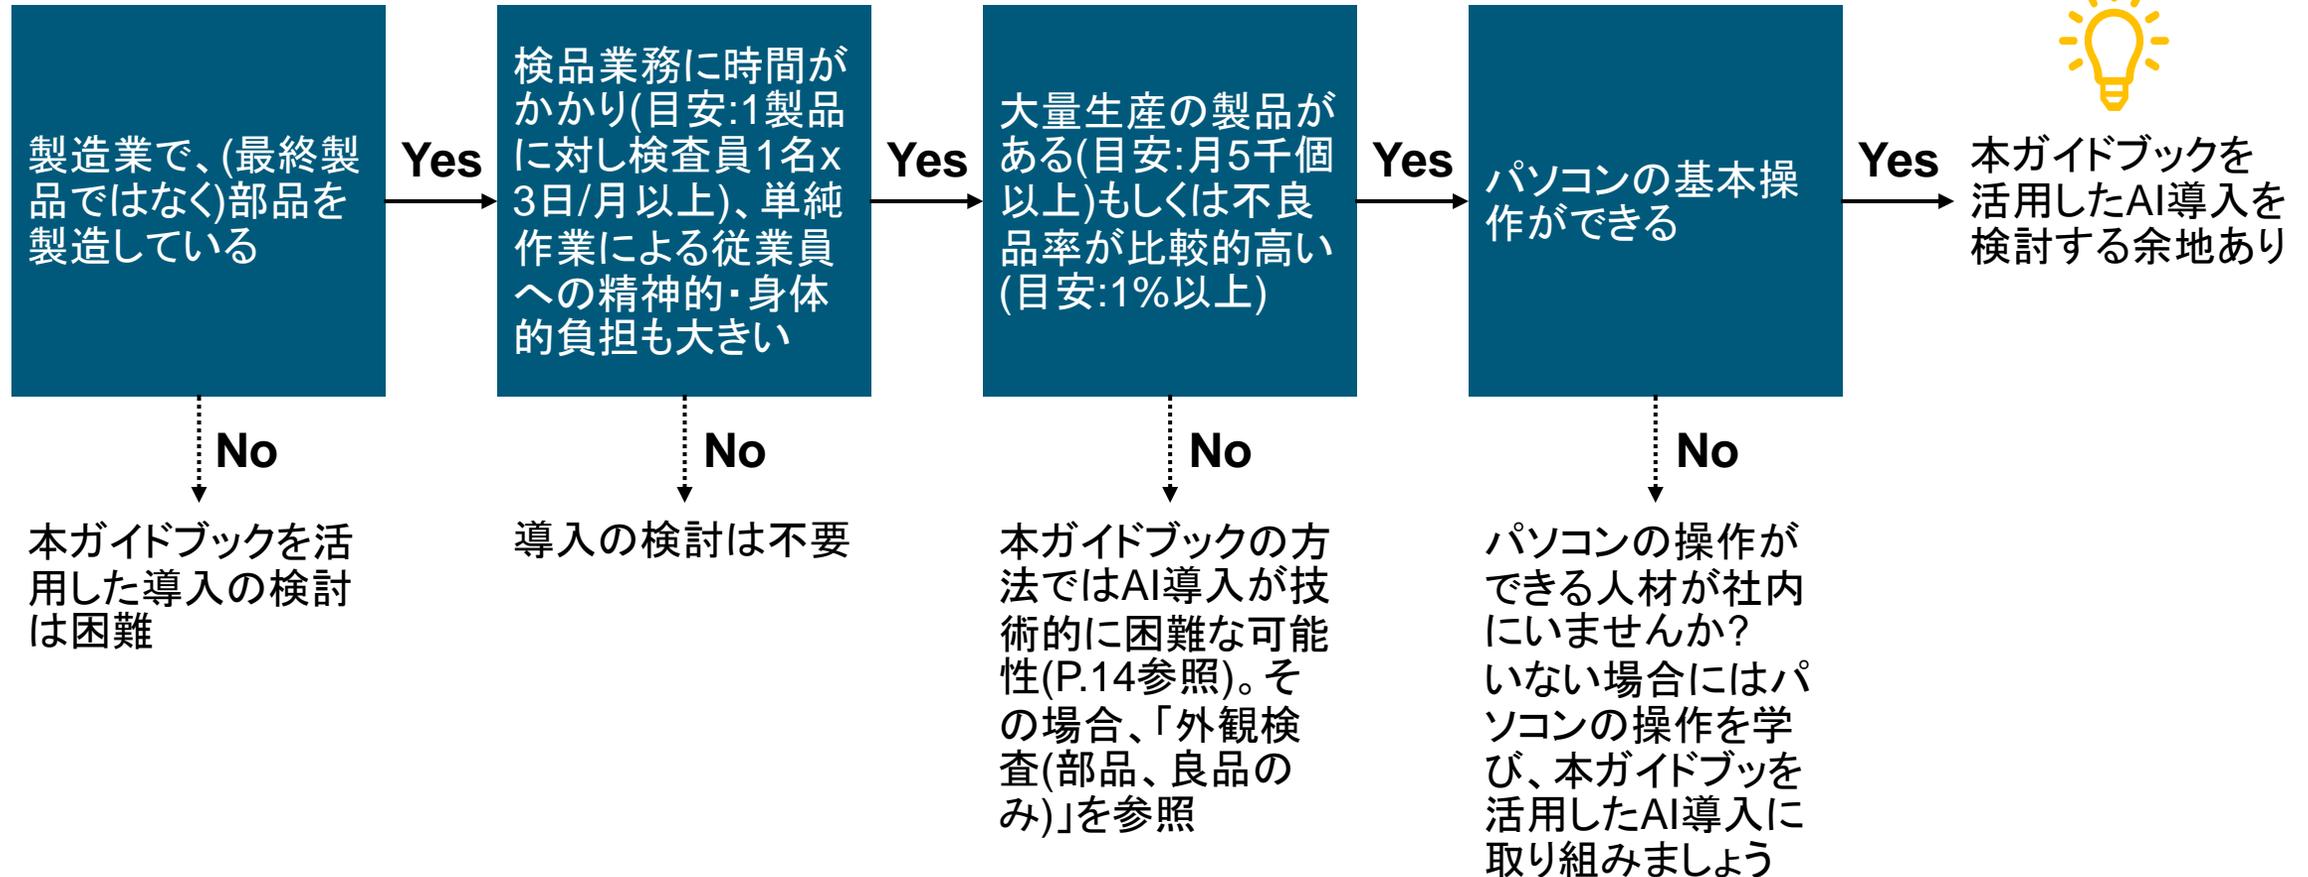
- 会社を良くするために、新技術の導入を試みたいと思っている
- パソコンの基本操作ができる
- 月数万個単位で生産している製品がある



1. 最終製品となる前段階の製品

本ガイドブックの対象者および目指すこと(2/2)

対象者に当てはまるか、チェックリストで確認してみましょう



外観検査ガイドブック目次

読んでいただきたい範囲

始めに



本ガイドブックで紹介するAIの機能・効果概要と
実証実験の概要・結果

P.5

導入工程



導入工程全体像

P.15

企 画

P.22

モデル構築

P.38

導入・運用

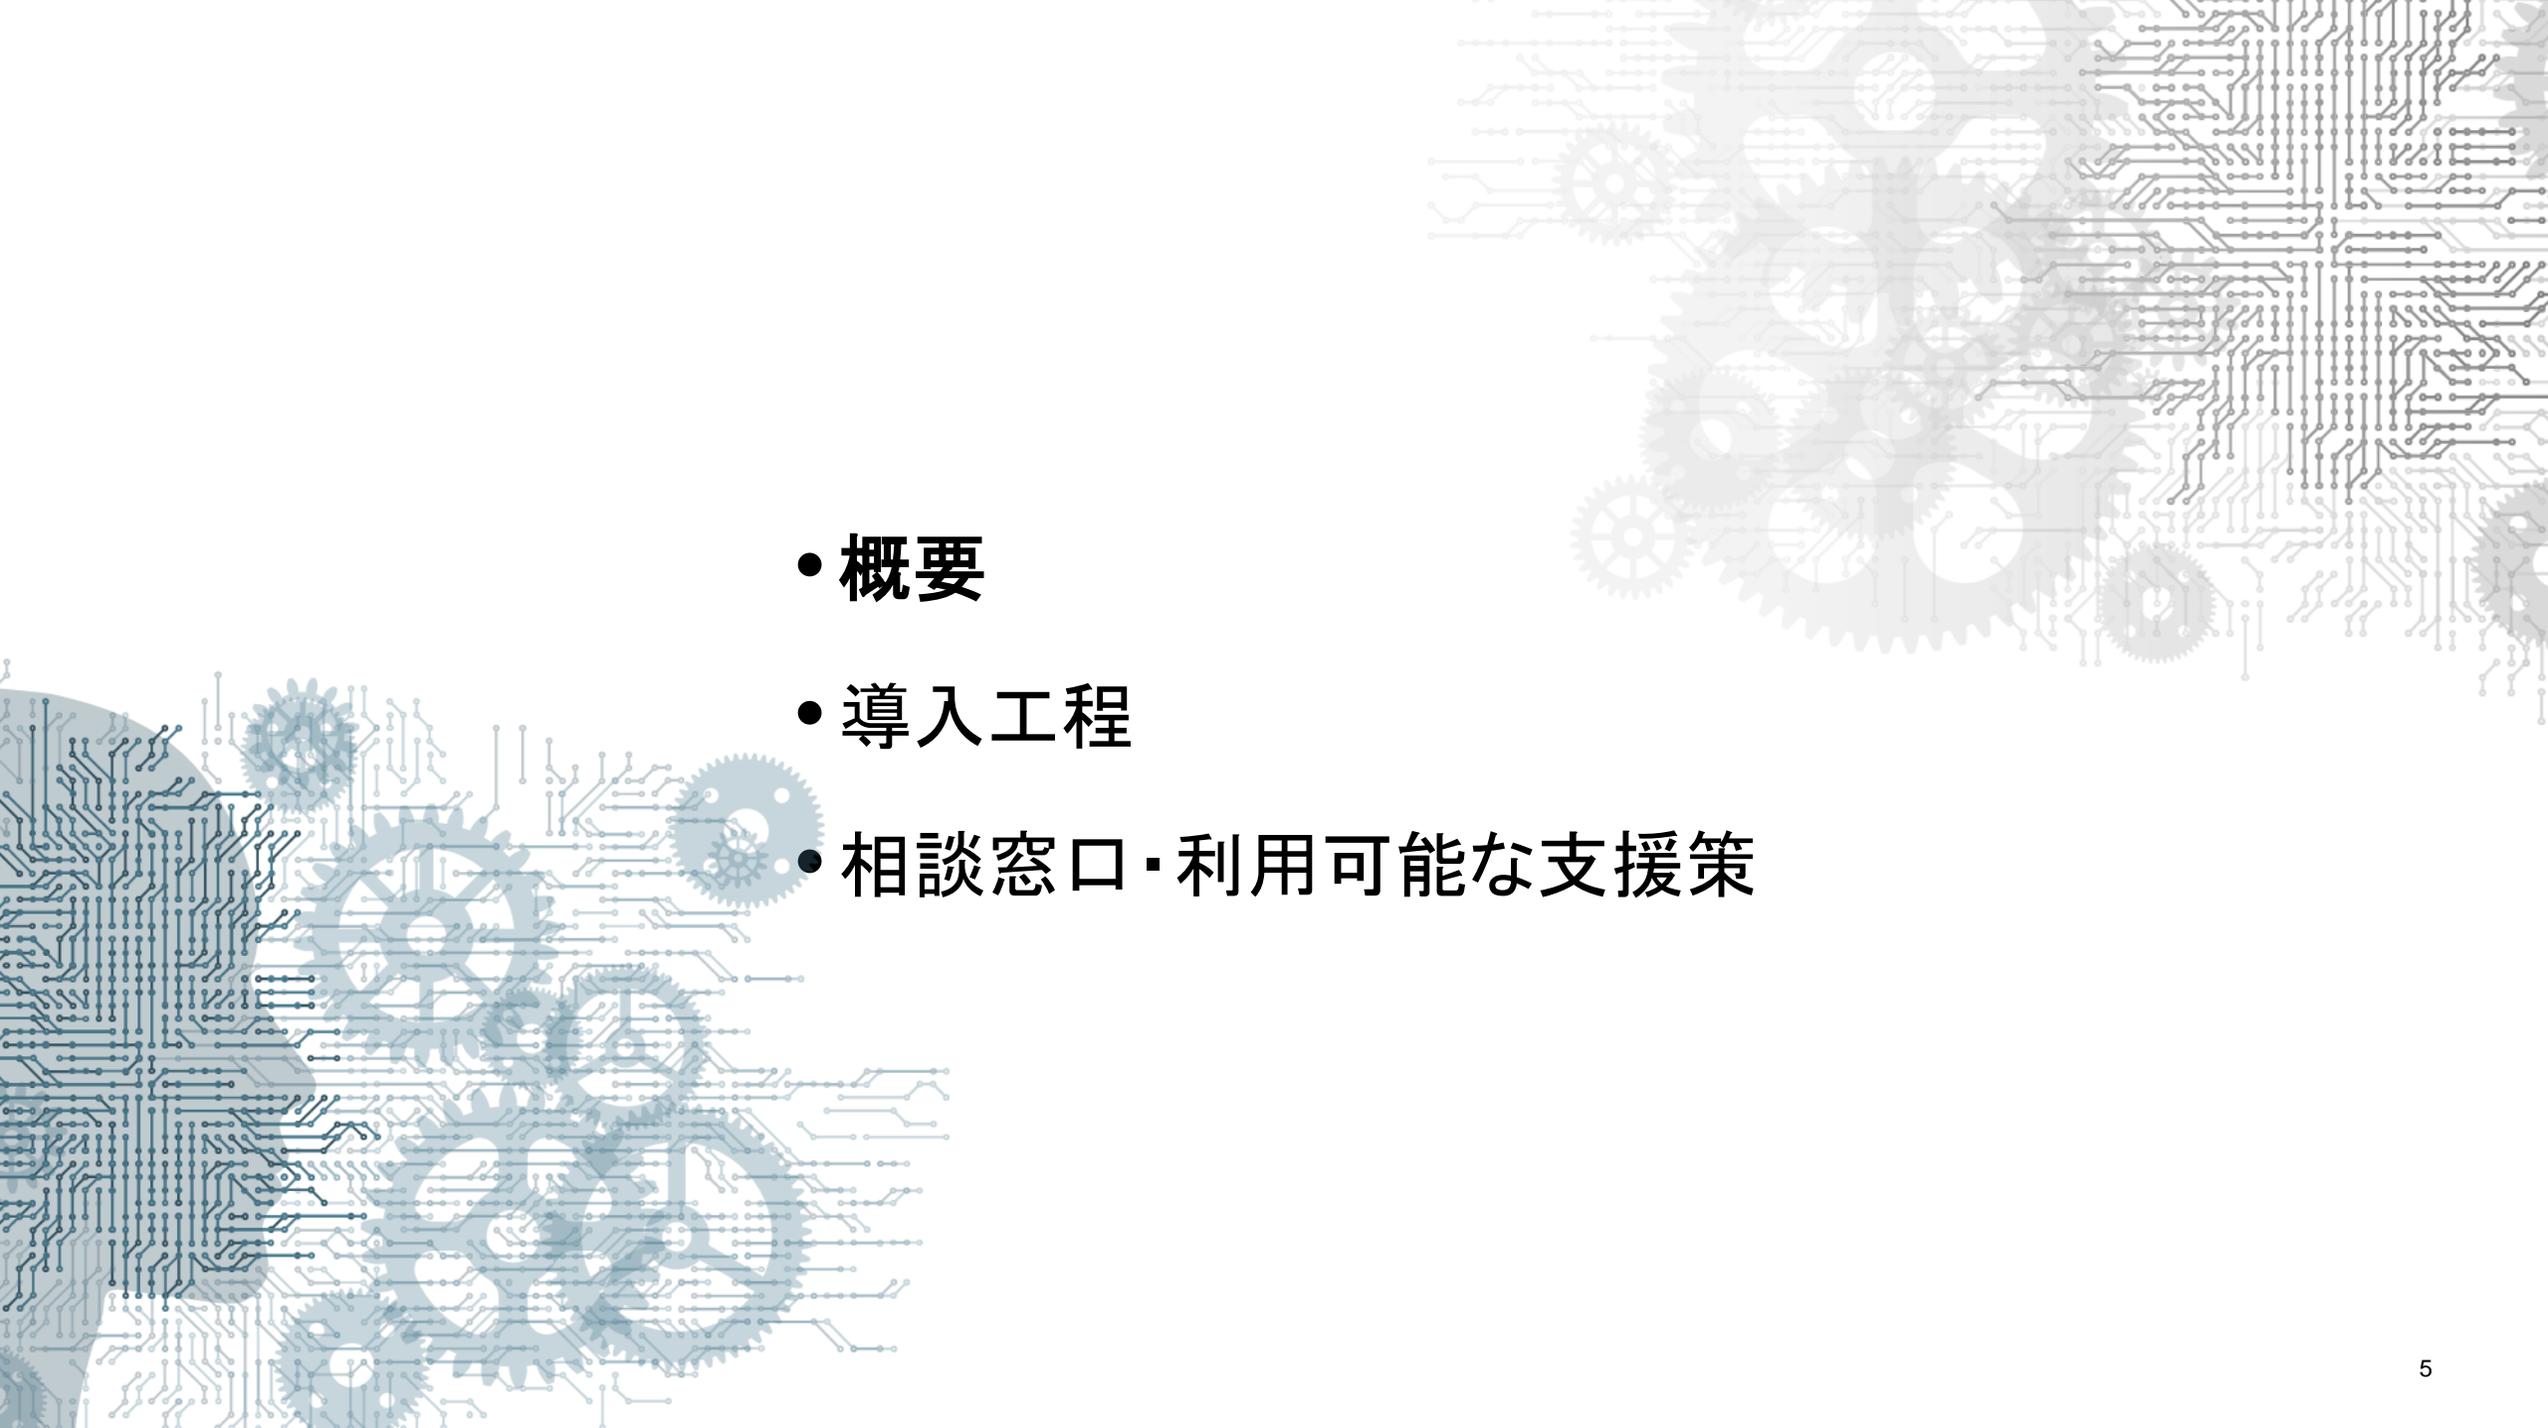
P.59

相談窓口・
利用可能な
支援策



P.69

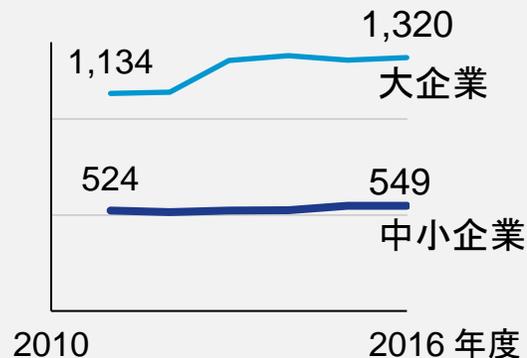
読んでいただきたい範囲	
経営者	
	AI導入担当者

- 
- **概要**
 - **導入工程**
 - **相談窓口・利用可能な支援策**

中小企業の直面する課題は、人手不足・生産性等多岐に渡るが...

1人当たり労働生産性¹

万円/人; 製造業



中小企業の生産性は大企業に比して低く、横ばい

中小企業の高齢化が進んでいる

従業員における60歳以上の割合

24%	13%
中小企業	大企業

中小企業に対する3年目の離職率

44%	31%
新卒	中途

中小企業の離職率は3年目3割を超える

中小企業の人手不足は年々深刻化

従業員が「不足」と回答した中小企業

23%	7%
2019年	2009年

1. 労働生産性=付加価値額/従業員数。付加価値額=営業純利益(営業利益-支払利息等)+役員給与+従業員給与+福利厚生費+支払い利息等+動産・不動産賃借料+租税公課

... AI技術は生産性改善だけでなく、従業員満足度の向上・技術継承促進と若手の育成・IT人材の採用等、中小企業の様々な経営課題の解決へつながり得る

中小企業への
AI導入による
推定経済効果

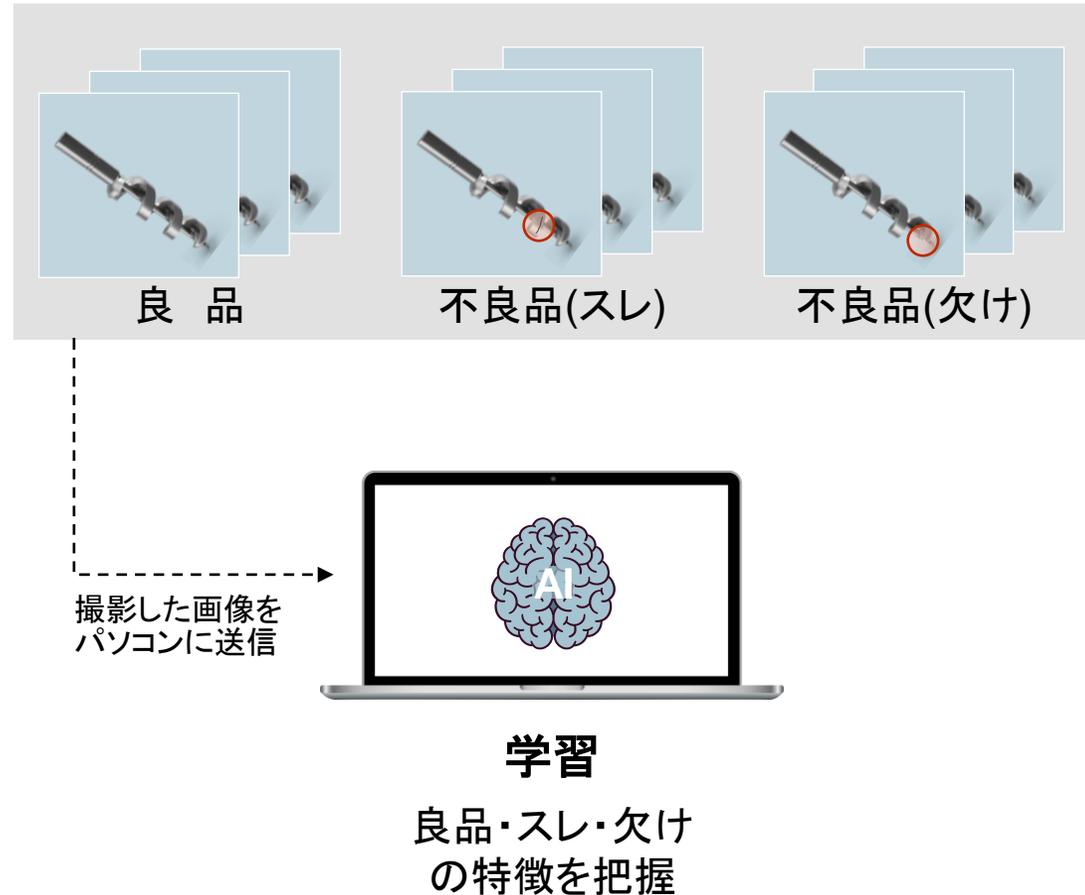
11兆円

(2025年まで)

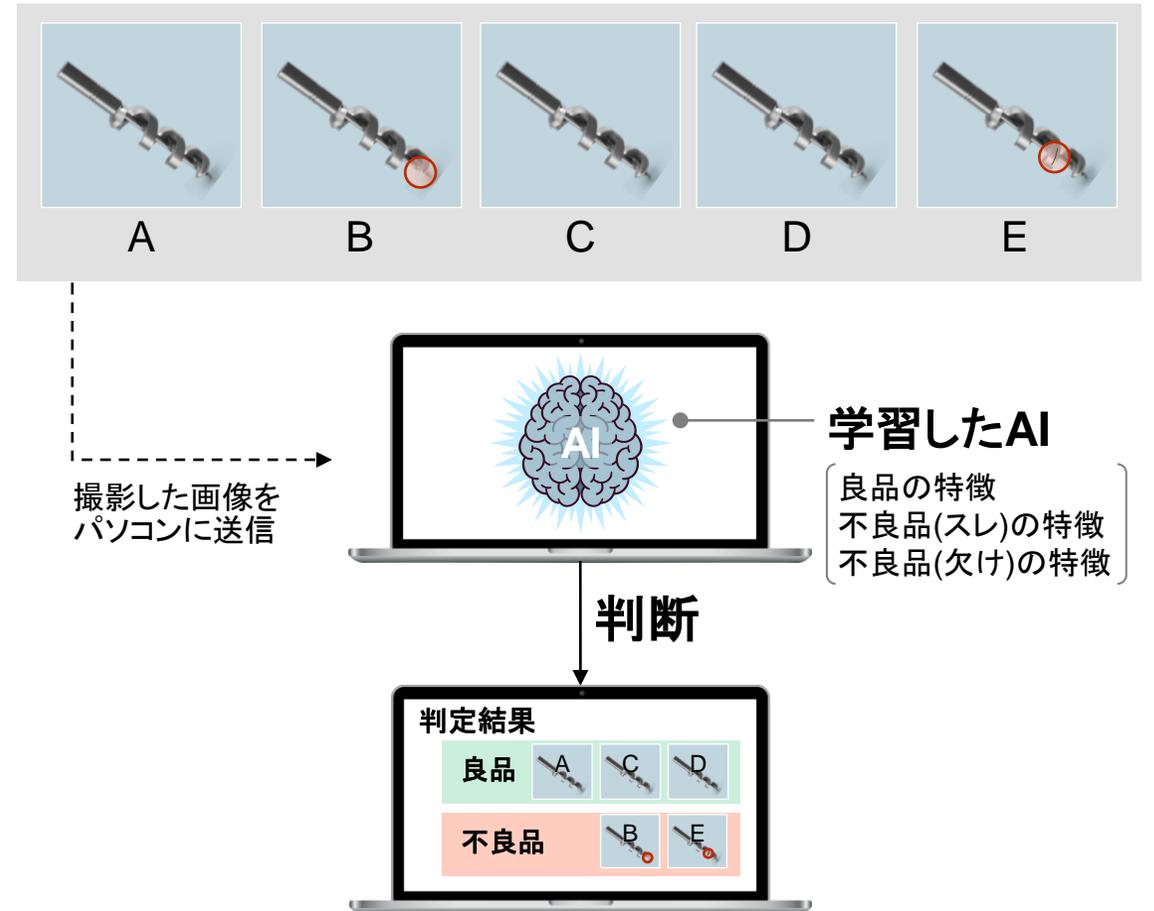


AIを活用した外観検査 – AIに良品・不良品の特徴を学習させ、不良品を検出させることで、検査工程の効率化が可能

AIが良品・不良品の特徴を学習



実際の検査で製品の画像を基にしたAIが自動で良品・不良品を仕分け



導入事例: ヨシズミプレス(1/2)

実証実験 企業概要

- 株式会社ヨシズミプレス
- 従業員18名
 - 業種 製造業素材型 プレス
 - AIを適用した製品: 直径5mm程度のレーザーダイオード部品



吉住研専務取締役

“ ” 町工場がAIを活用するなんて遠い先のことだと思っていました。モデル構築のプロセスも理解しやすく、知識がなくても挑戦できました

業務の 変化

導入前

月当たり50万個の製品を目視検査
検査員6名で約10日間かかっていた



“ ” 品質が厳しい製品なので小さな傷や変形を見落とさないよう神経を使っていました。顕微鏡を覗きながらの検品は心身ともに負担が大きいです

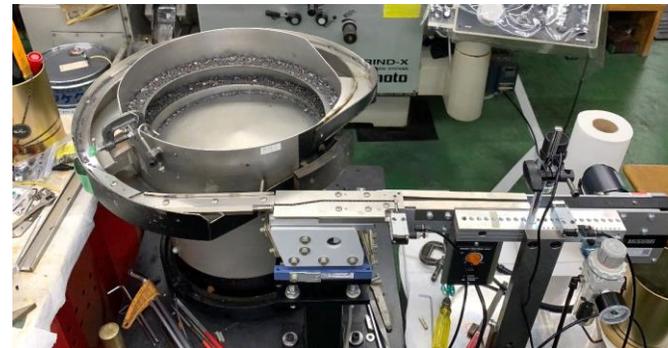
 検査担当者

導入後

検査に要する総時間¹が約**40%削減**

検査員が目視で検査する製品数が**95%削減**(月50万個 → 2万個)

製品をベルトコンベアにつながる
整列機に投入



整列した製品をAIが
判定し、不良品は自
動でベルトコンベア
上から除外



AIが良品と判定した製品(約48万個)は良品としてそのまま出荷

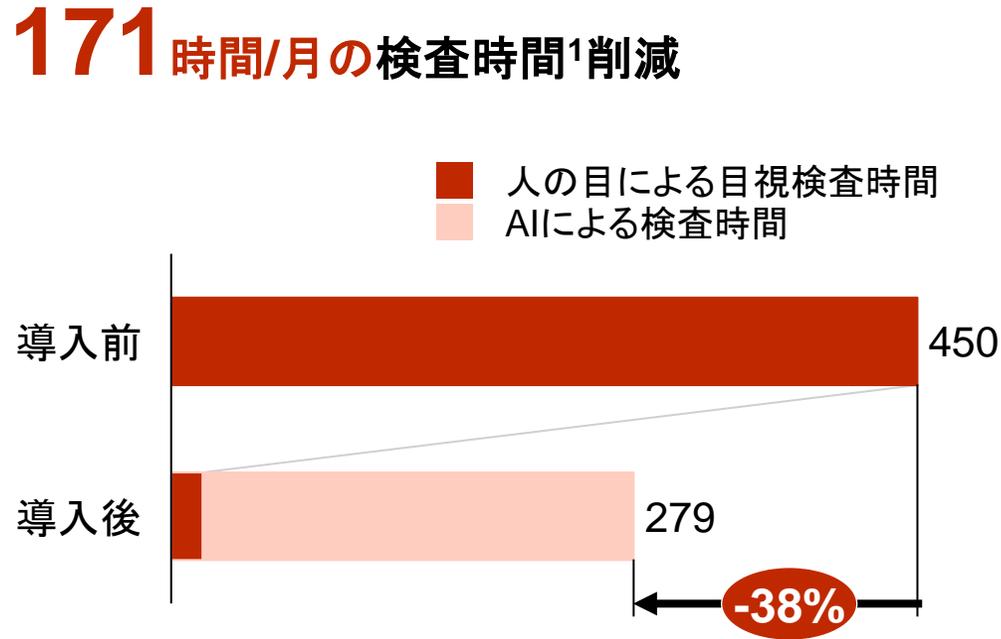


AIが不良品と判定した製品(約2万個)には不良品と良品が含まれるため、再度検査員が目視検査

1. 休憩時間除く

導入事例: ヨシズミプレス(2/2)

効果



利益増加



人手の掛かる検品作業のオートメーション化が可能になり利益率アップにつながりました。他のアイテムへも展開していきたいです



現場監督者

従業員の満足度向上



長時間神経を使っていた検査をAIに任せられることになりストレスから解放されました。空いた時間で生産性アップへの改善作業に専念できるようになりました



検査担当者

リソース

導入費用 約**30**万円 導入期間 約**70**日

社内でプログラミングができる人材 **0**人

事前に用意していたデータ材 **なし**

1. 休憩時間除く

導入事例： 墨田加工(1/2)

実証実験 企業概要

墨田加工株式会社

- 資本金4,000万円、従業員約100名
- 業種 製造業基礎素材型 プラスチック加工
- AIを適用した製品: 3cm程度の円筒状プラスチック加工品



鈴木洋一社長

業務の 変化

導入前

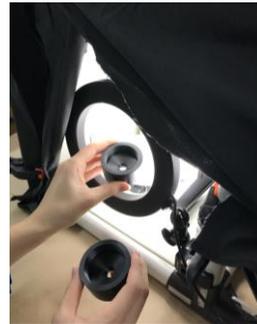
- 1ヵ月当たり約4,320個を目視検査
- 検査員2名で3日間²の検査を実施



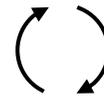
“ ” 数千個も同じ製品の細かい傷を見続けるのは目が疲れるし...

導入後

- 目視検査の時間²が**36%**削減



製品を箱より取り出し、AIが入った検査機械に人手で製品をセット。AIがOK・NGを判断



AIの検査を待つ間、AIで検査できない部位(製品内部等)を目視検査



OKと判断されたものは良品としてそのまま出荷



NGと判断されたものから良品を除くため、再度検査員が目視検査

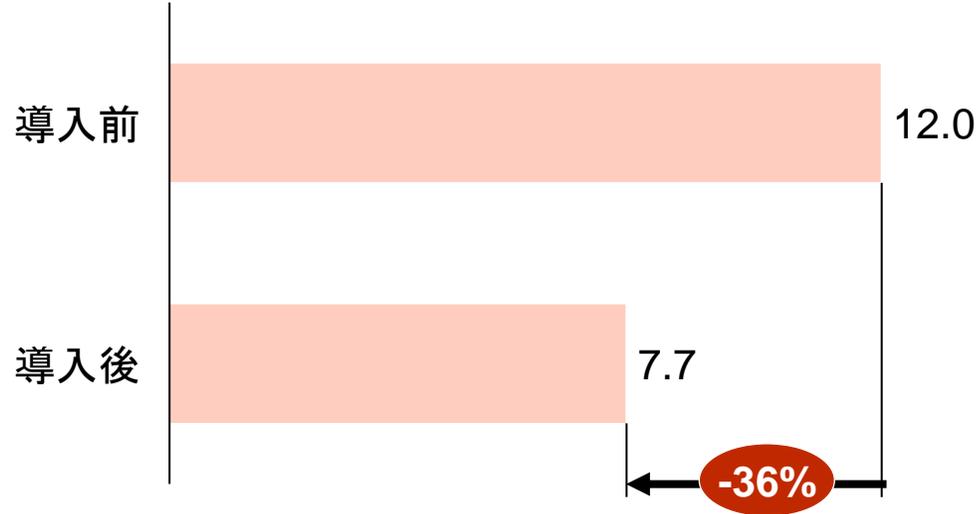
1. 梱包や休憩時間を含む
2. 目視で製品を検査している時間のみ。梱包や休憩を除く

導入事例: 墨田加工(2/2)

効果

36%の目視検査時間¹が削減

月当たり目視検査時間(時間)



技術継承の促進・若手の育成

“ ” “人”の熟練度合にかかわらず導入直後から安定した結果が得られる点が最大のメリット。AIの判定結果から人が学ぶことも可能

副工場長



従業員の満足度向上

“ ” 目視検査の「中心視」で重要箇所をAIに託すことで、検査員は別箇所を「周辺視」で済むことになり疲労軽減、見逃し低減、検査精度向上に繋がると期待は大きい

品質管理担当者



“ ” 『AIを活用する事により、検査員の目視検査時間削減。合否のバラツキ。ヒューマンエラーがなくなる事を期待できる

品質管理担当者



リソース

導入費用 約**15万円** 導入期間 約**70日**

社内でプログラミングができる人材 **0人**

事前に用意していたデータ材 **なし**

1. 目視で製品を検査している時間のみ。梱包や休憩を除く

AI導入企業からの激励

AIは導入してからも日々改善が必要。数年間の長期の取り組みにはなるが、確実に現場にとっての利益があるので、是非頑張ってもらいたい

武州工業
林英夫 代表取締役 会長



データ活用、AI導入は単なる改善活動ではなく、製造業にとって、生産プロセスの革新と考えます。日本のものづくり現場にこそ、大きなチャンスがあると信じてるので、もっと仲間を増やしていきたい

山本金属製作所
山本憲吾社長



「経験と勘」に頼っていたことをAIで行うことで、人間はもっと人間にしかできない創造的な仕事ができるようになります。以前に比べるとかなり安く・簡単にAIを使える時代になってきているので、是非積極的に活用してほしい

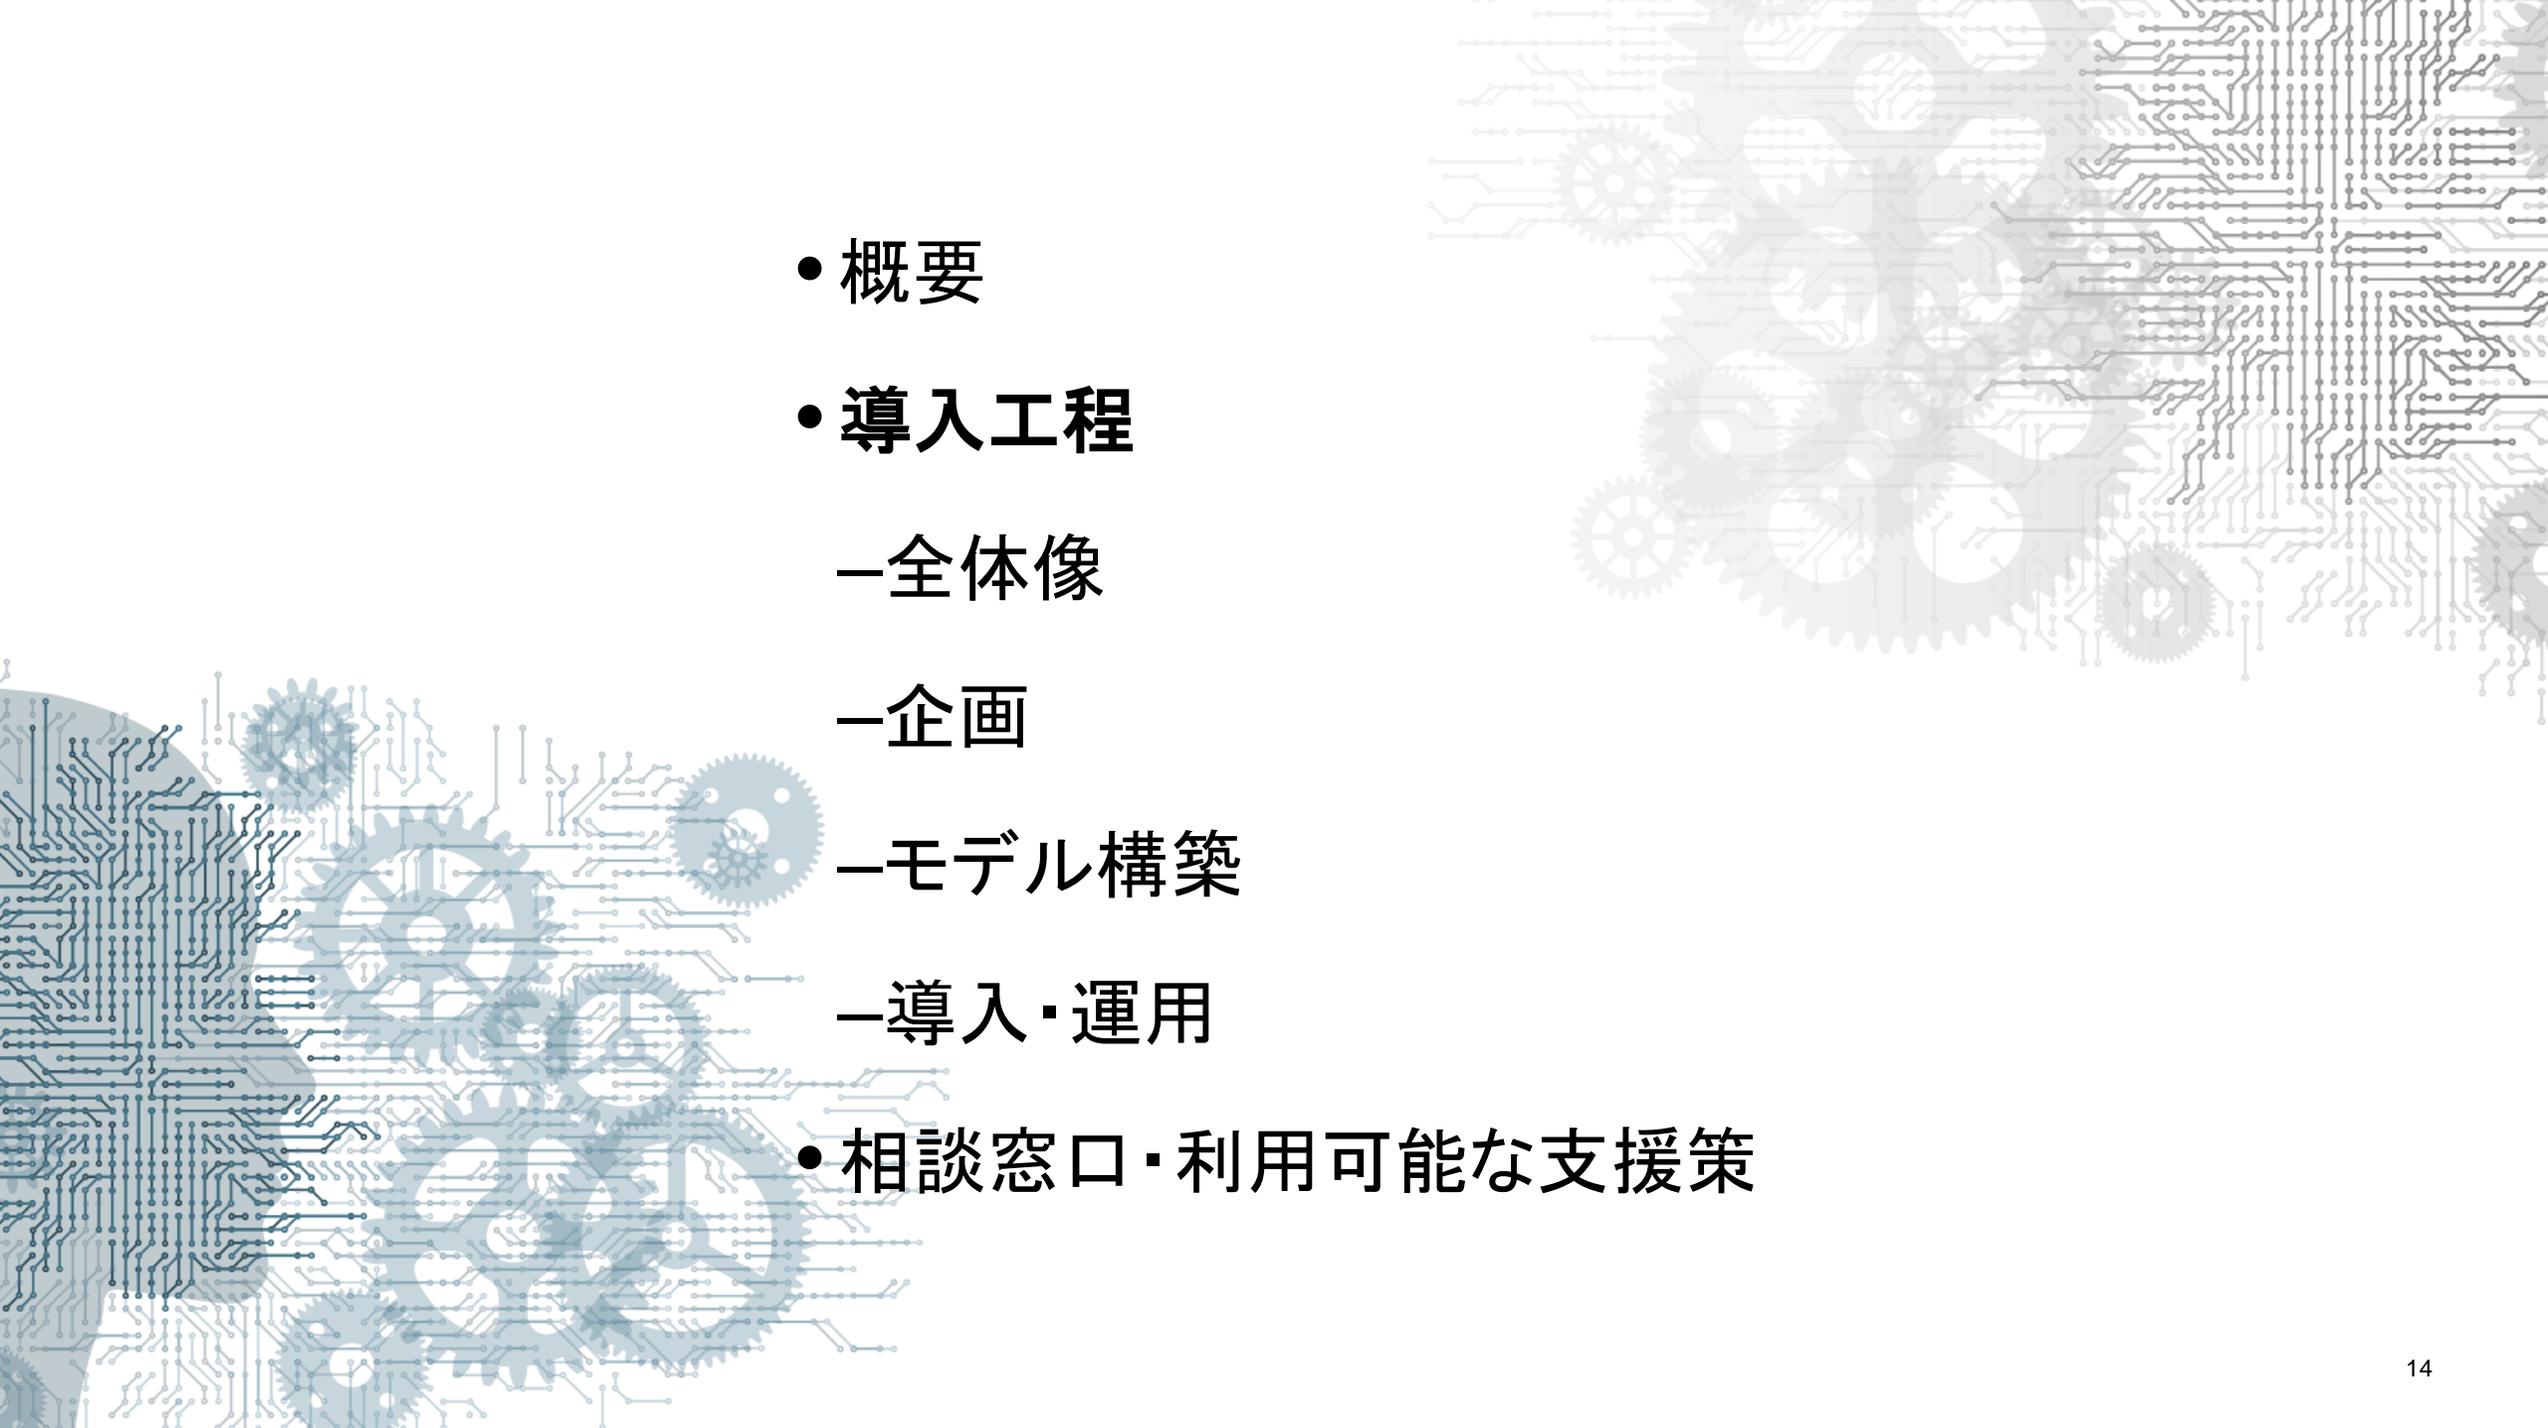
グッデイ
柳瀬隆志社長

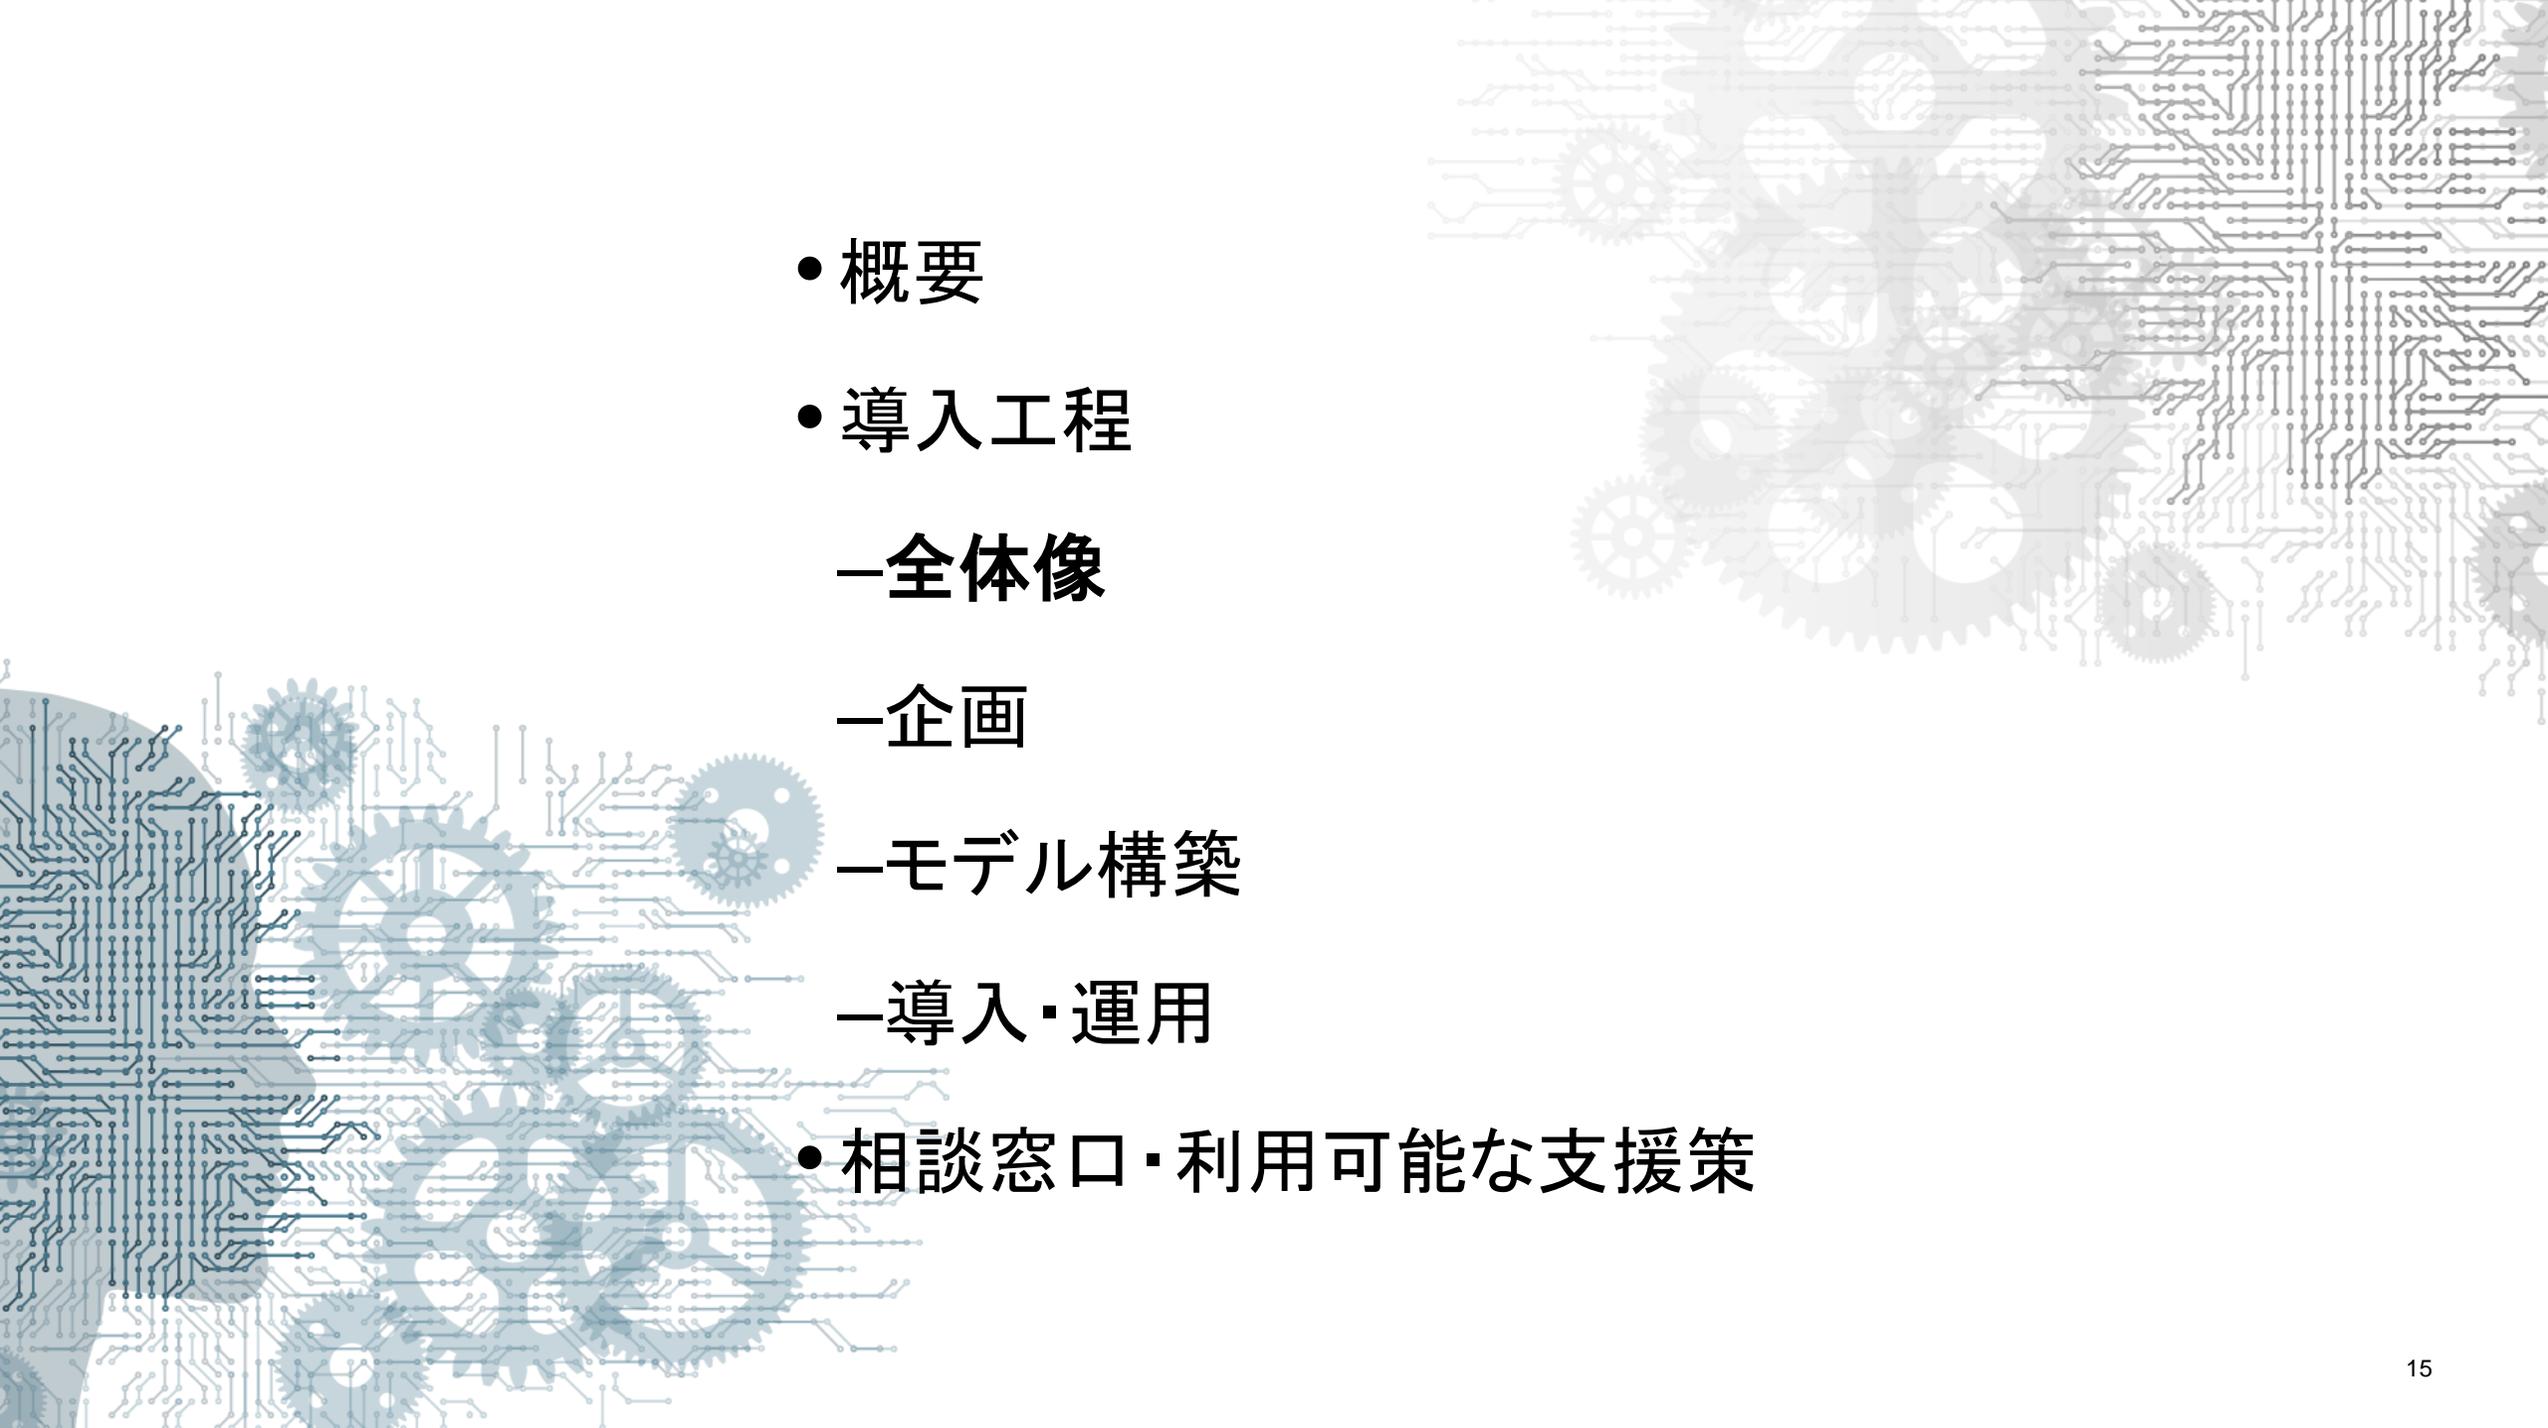


働き方改革・資材高騰・品質保証...
製造業の経営環境は厳しくなる一方、それでもなお利益を出し続けなければなりません。AIは単なる省人化ではなく、検査精度の向上、ロスコスト削減など、製造業にとって救世主となる可能性を秘めています。一朝一夕にはいきませんが是非挑戦してみてください。

ヨシズミプレス
吉住研 専務取締役



- 
- 概要
 - 導入工程
 - 全体像
 - 企画
 - モデル構築
 - 導入・運用
 - 相談窓口・利用可能な支援策

- 
- The background of the slide features a complex, light blue and grey graphic. It consists of several interlocking gears of various sizes, overlaid with a dense network of circuit-like lines and nodes, resembling a printed circuit board or a digital data network. The overall aesthetic is technical and futuristic.
- 概要
 - 導入工程
 - 全体像
 - 企画
 - モデル構築
 - 導入・運用
 - 相談窓口・利用可能な支援策

外観検査AI導入の分岐点: 不良品の多寡(生産量、不良品率)によってAI導入工程が異なる。本ガイドブックでは短期間で不良品を十分に用意可能な場合の方法を説明

短期間で不良品を十分に用意可能
(大量生産の場合が多い)

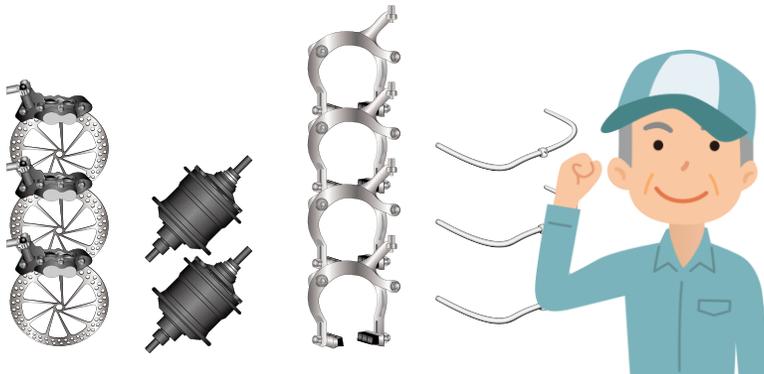


プログラミング知識なしでもモデル構築ができるGUI¹の活用が可能

外観検査AI導入は不良品の集めやすさに応じて大きく2つに分かれる

▶ 本外観検査AI導入ガイドブック(部品、不良品あり)ガイドブック参照
(GUI¹によるモデル構築)

短期間では不良品の用意が困難
(不良品率が低い、不良の種類が多い等、少量生産の場合が多い)

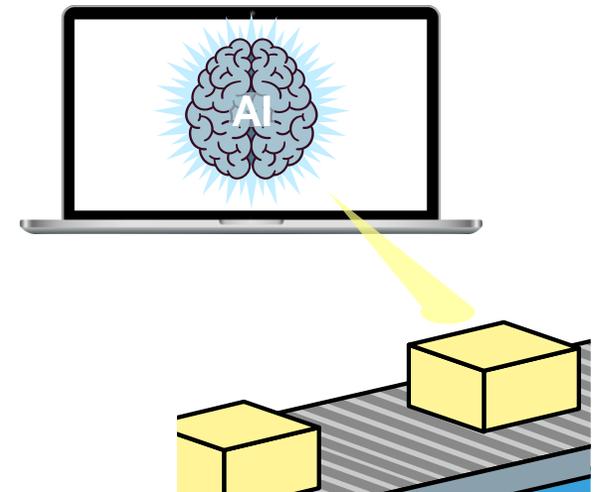
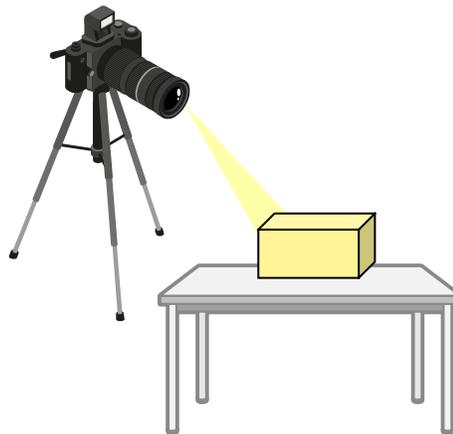
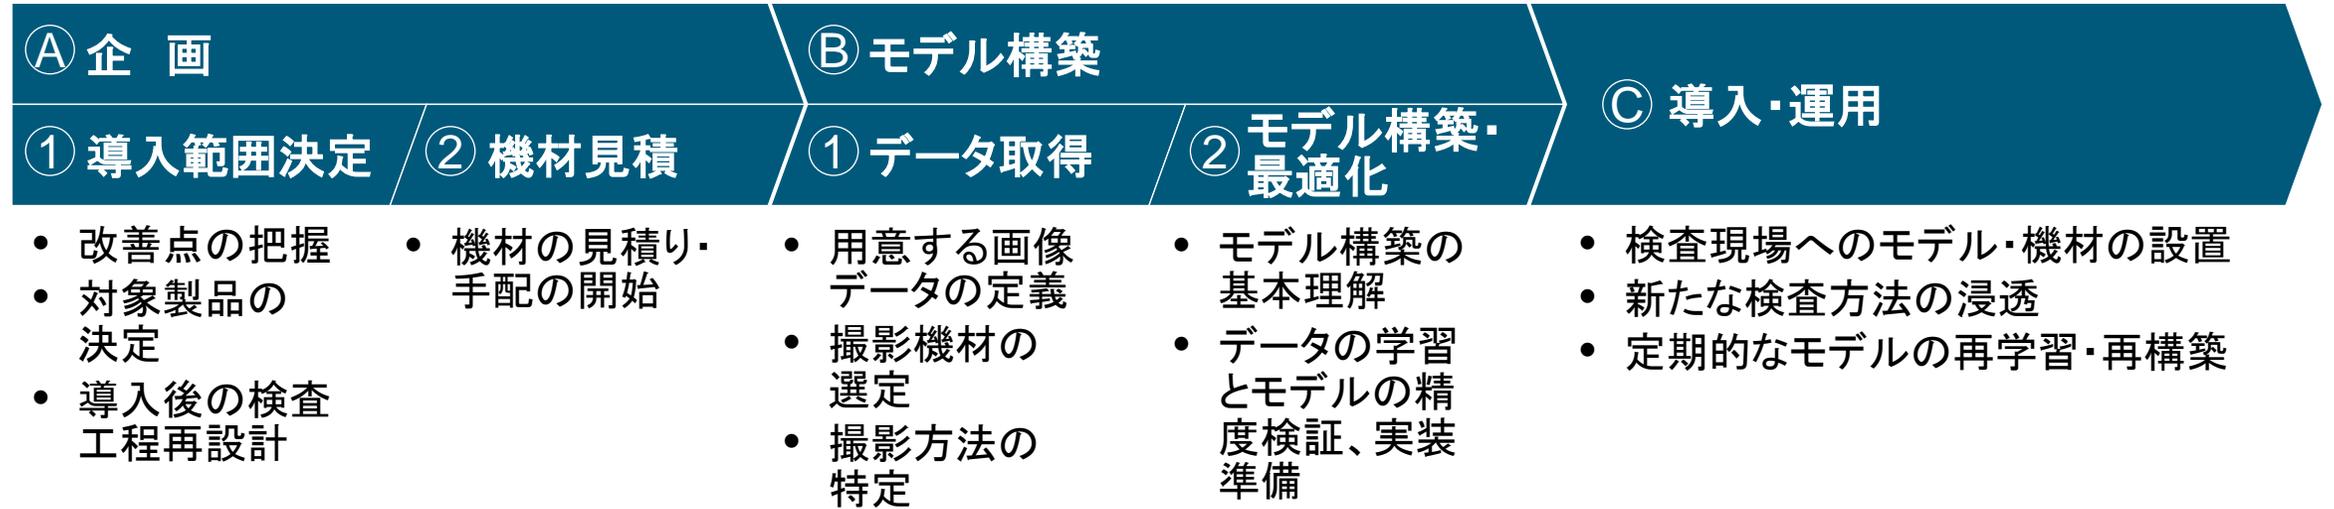


良品のみでモデルを構築する方法もあるが、プログラミング知識が必須のため難易度は高い

▶ 外観検査AI導入ガイドブック(部品、良品のみ)参照

1. GUI=Graphical User Interfaceの略。マウスのクリックやドラッグで操作が完結

企画から導入・運用までの導入工程全体像



本ガイドブックでの導入を通じて達成されている状態

本ガイドブックでの導入を通じて、AIを活用した業務・組織変革への最初の一步を踏み出す状況になることを目指している。具体的には...

業務の変化



検査を行う**初期的なAIのモデル構築**が完了している



AIを活用した新たな検査工程が運用され始めている



AI活用により、**検査における単純作業の負担が軽減**している

組織の変化



ITベンダー任せでなく、自社が主体となってAI活用を進められる程度**のAIに関する知識を獲得**している



AIの活用が自分事化され、**積極的な活用に取り組む文化**が生まれ始めている

導入工程に沿った「導入方法の工夫」

製品の規格や検査条件に合わせ、具体的な導入方法は工夫が必要

典型的に必要な導入方法の工夫とその例



- 改善点の把握
- 対象製品の決定
- 導入後の検査工程再設計

- 機材の見積り・手配の開始

- 用意する画像データの定義
- 撮影機材の選定
- 撮影方法の特定

- モデル構築の基本理解
- データの学習とモデルの精度検証、実装準備

- 検査現場へのモデル・機材の設置
- 新たな検査方法の浸透
- 定期的なモデルの再学習・再構築

工夫あ

導入工程における機械自動化度合い(検査のための撮影に常に人手を要するか)に応じた工夫

あ1 撮影のための製品の配置を手で実施

あ2 撮影のための製品の配置を機械で実施(機械で行っても費用対効果がある)

工夫い

製品の撮影方法の工夫(どのような機材を使って撮影するか)

い1 平面のみの撮影(例: 平らな製品)

い2 撮影角度の微調整が必要(例: 曲面を持つ製品を回転させながら撮影)

導入工程推進に要する時間の目安

 意思決定者

実証実験での 分担例

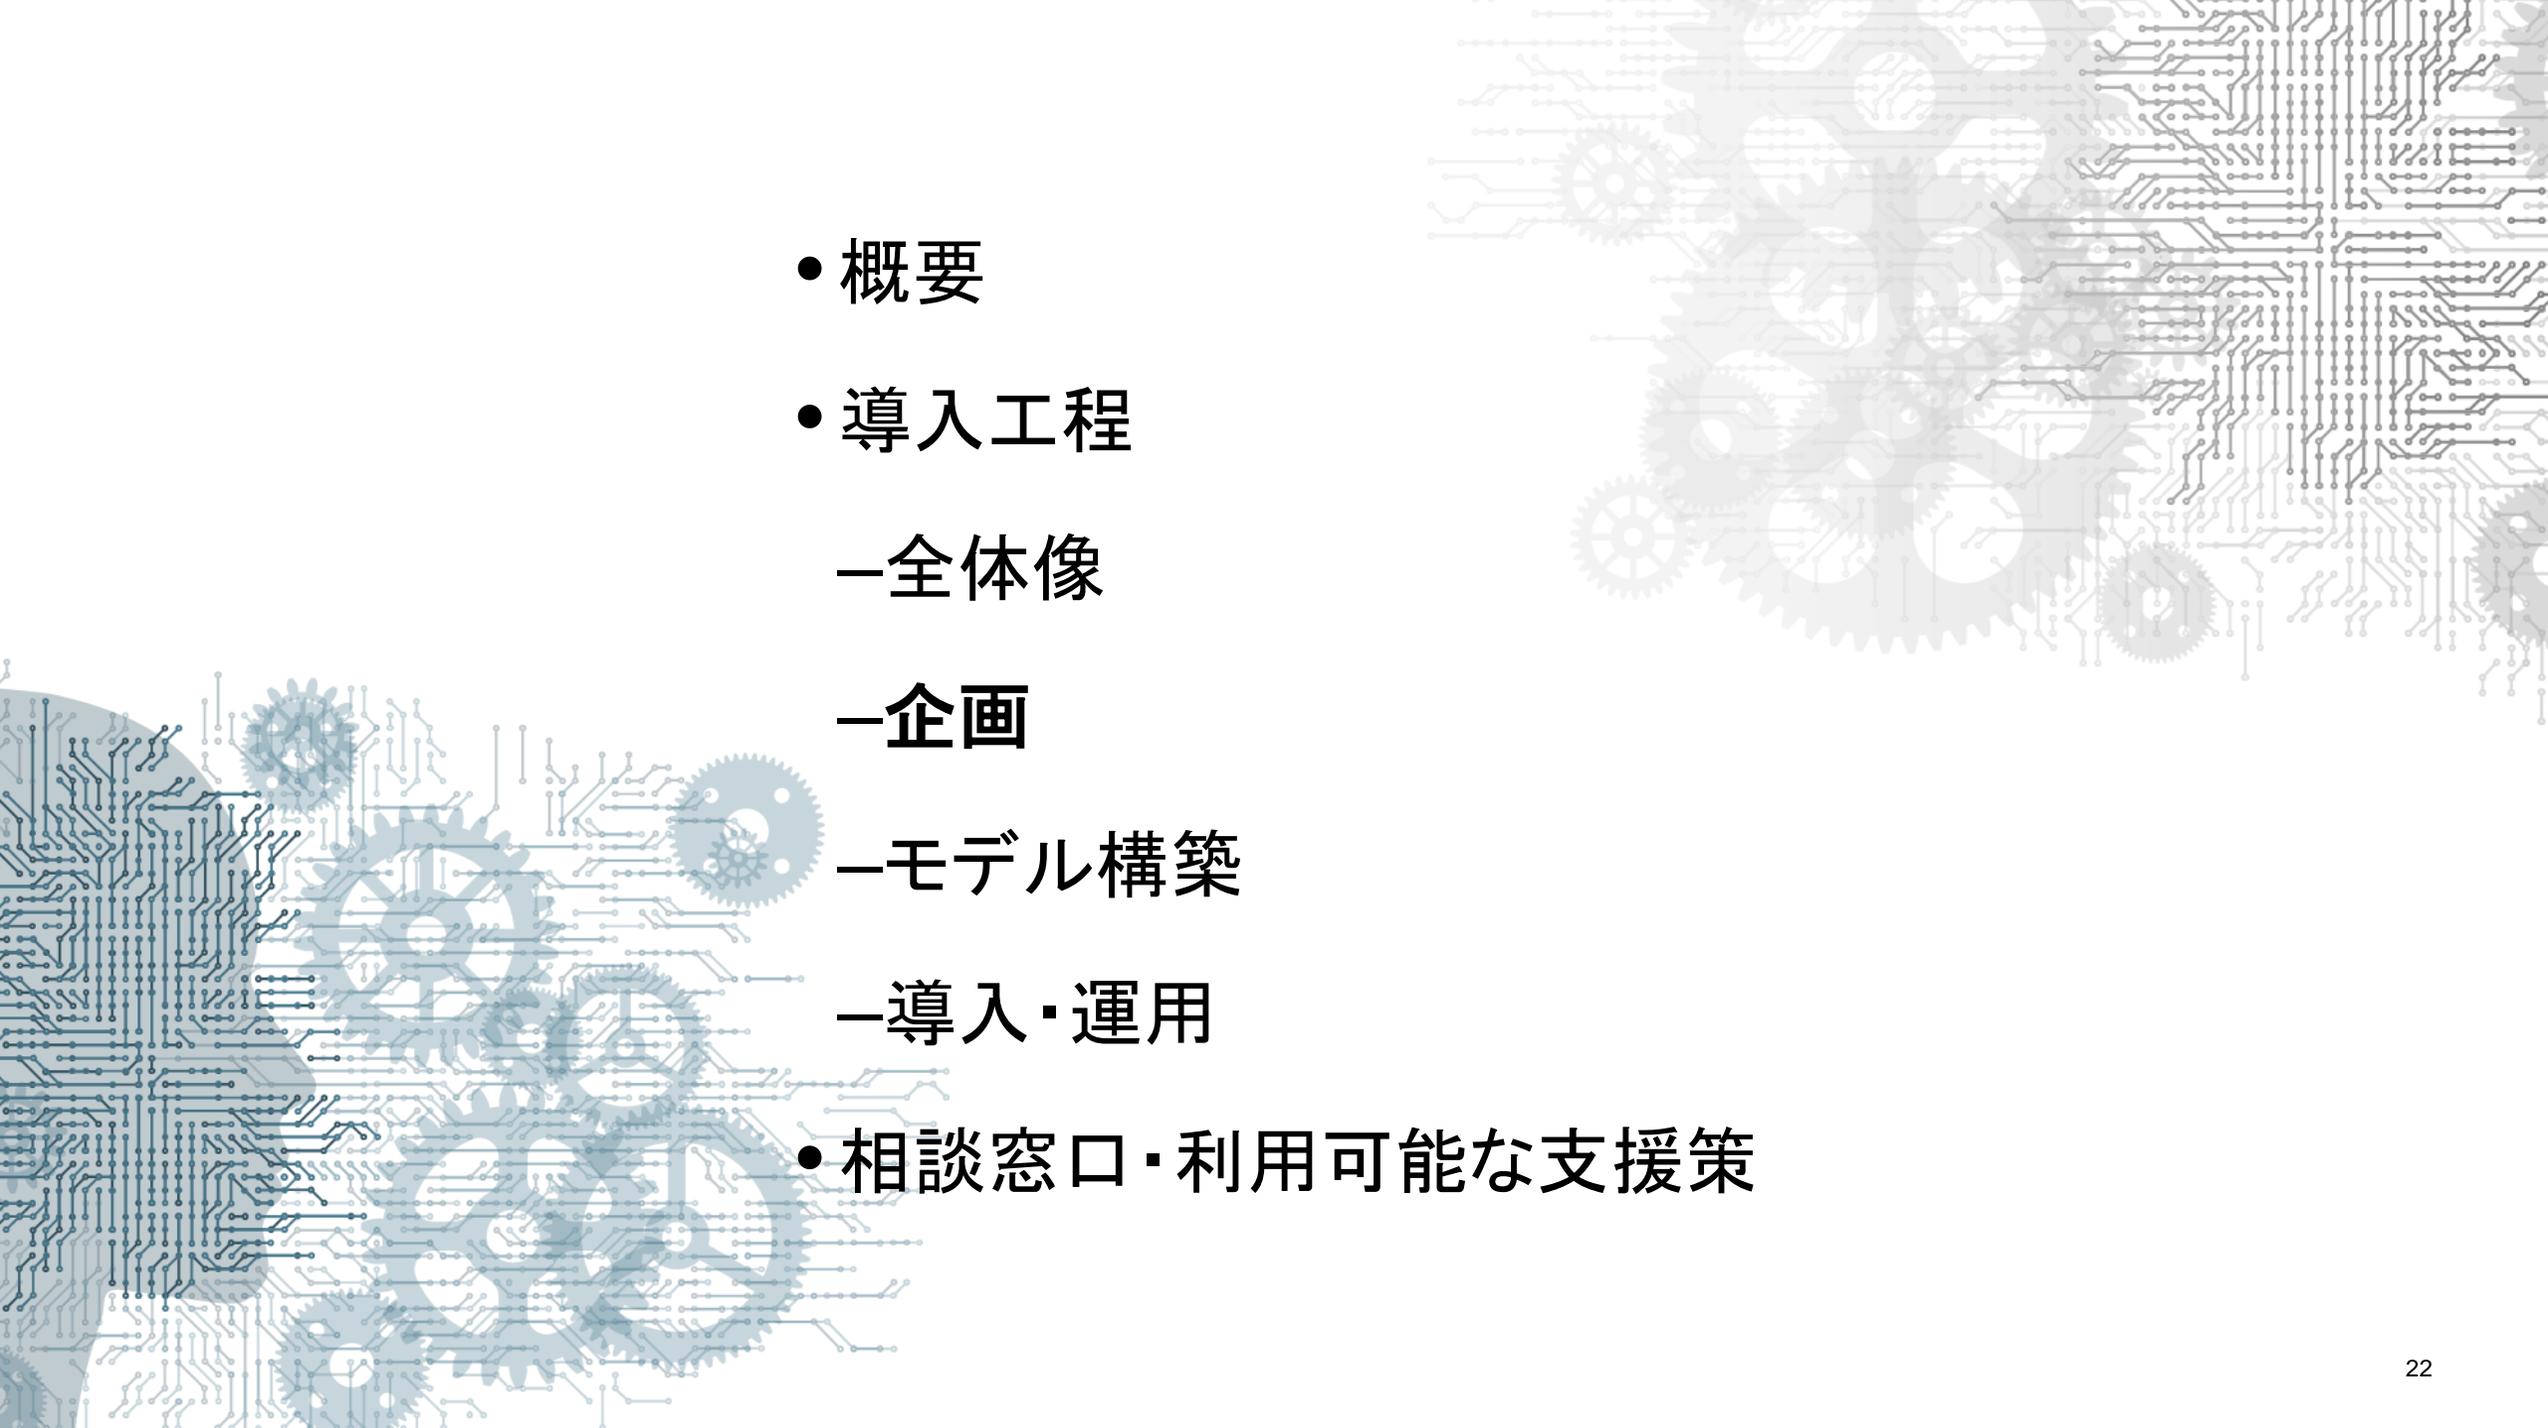
		作業具体例	時間目安 (時間)	導入 事例A	導入 事例B
意思決定		<ul style="list-style-type: none"> 導入可否の検討 検査方法変更に対する納入先の許可獲得 	~10		
導入 工程 ¹	A1 導入範囲決定	<ul style="list-style-type: none"> 導入後の検査工程再設計 情報収集 	~10		Aさん
	A2 機材見積	<ul style="list-style-type: none"> 検査機材設計 検査機材作成 	10~250 ²		Bさん
	B1 データ収集	<ul style="list-style-type: none"> 製品の準備 撮影 	~10		
	B2 モデル構築	<ul style="list-style-type: none"> GUIを使用したモデル構築 精度検証 	10~50 ³		Cさん
	C1 現場への導入	<ul style="list-style-type: none"> 担当者へのAIを活用した検査方法のトレーニング 	~3		
合計			50~330		

担当者の技能や他業務を考慮して各業務を分担することで、効率よく短期間で導入を進めることが可能

1. 保守・運用除く
2. 機材の作成方法によって時間が大きく変わる
3. モデル構築・検証を複数回実施する場合には所要時間が増加

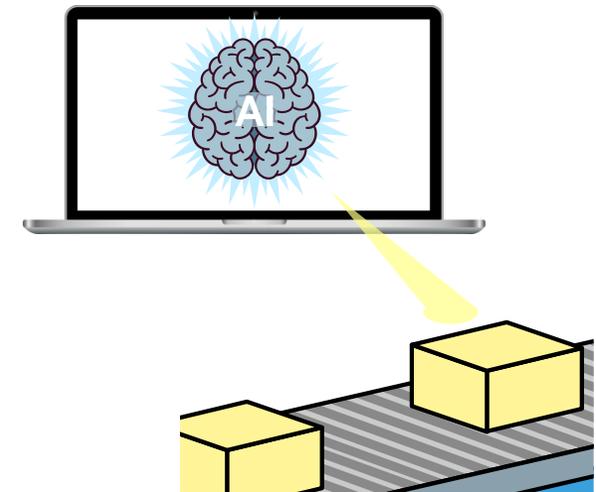
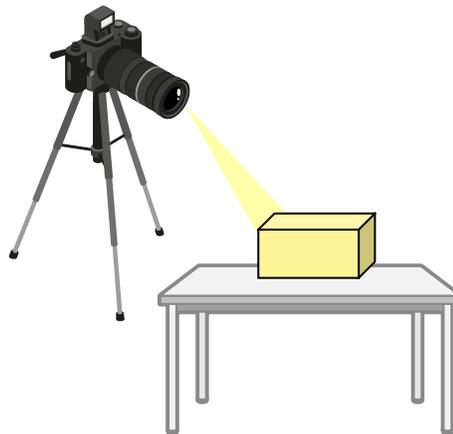
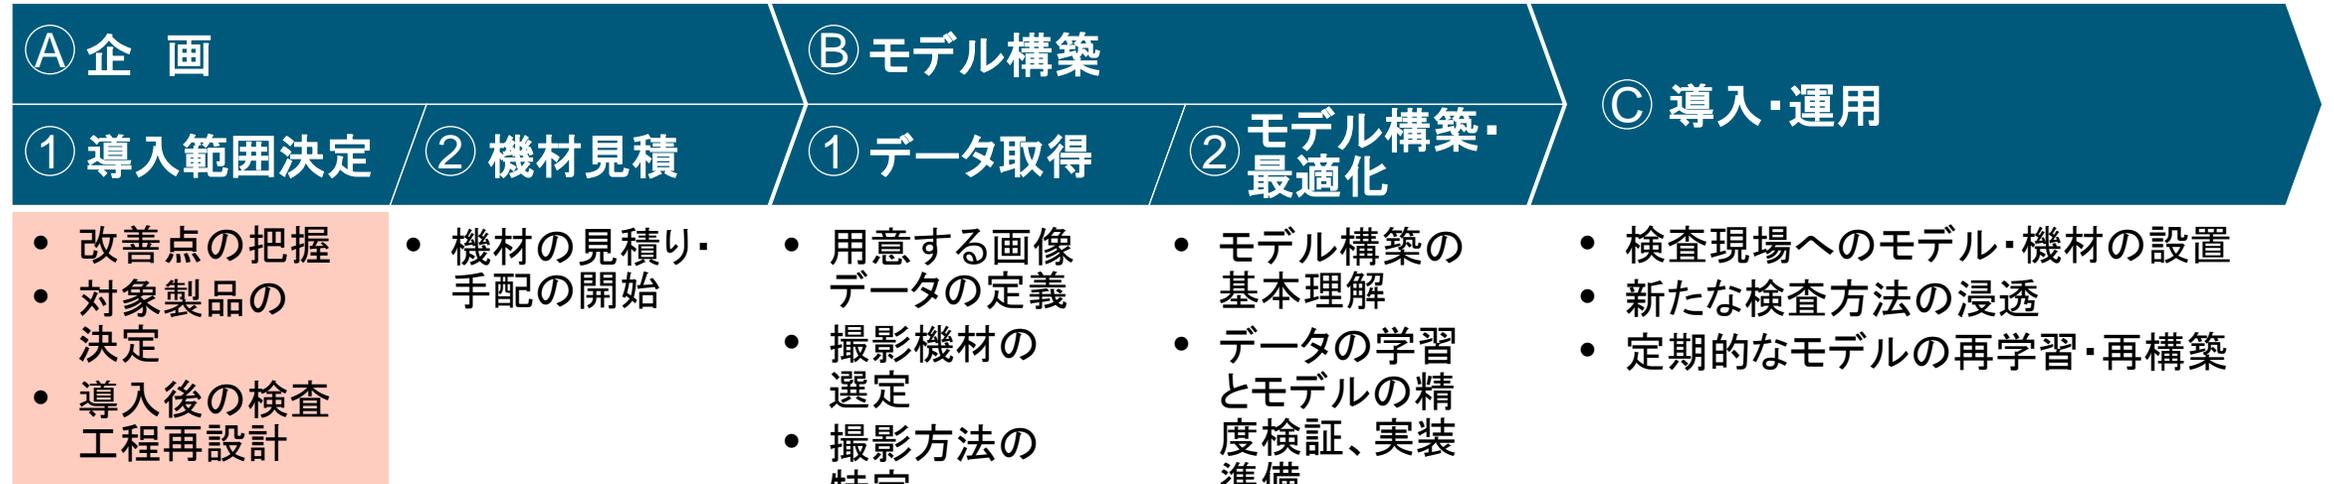
AI導入工程においてつまづきやすいポイント

A1 対象商品選定 不良品収集	不良品数の不足	<ul style="list-style-type: none">AI導入直前に製造の改善をしたため、不良品が大幅に下がってしまい、学習用の不良品がなかなか集まらない
	AI導入後の検査工程再設計が不完全	<ul style="list-style-type: none">対象製品のどの部位の検査をAIで置き換え、どこの部位の目視検査を継続するか、設計しきらずに進めたことで、後の工程で手戻りが発生した
B1 撮 影	製品の特徴や不良品全体像の把握	<ul style="list-style-type: none">肉眼では見えない製品の特徴を無視して学習データを取得した(例:製品の加工面の粗さが仕入れ先によって異なったが、粗い表面のみで学習を行った為、光沢のある表面の良品が不良品として判別されてしまった)AI導入開始時には不良品の種類が1種類しかないと思っていたが、他にも不良が見つかった
	不良品基準のブレ	<ul style="list-style-type: none">カメラだと、目視では確認できない傷が映り、不良と分類すべきか議論になった社内で不良の認識が異なり、作業者によって不良・良品の判断が異なっていたこれまで良品としていたものが、納入先から不良として除外するよう通告が入った
	撮影方法ミス	<ul style="list-style-type: none">撮影背景にゴミがついてしまい、学習データのノイズになった撮影の際に人の指が写り込んでしまっている画像があった(製品そのものは不良品だが)不良部分が写っていない写真を撮ってしまった(不良品の写真だとしても、不良箇所が写っていなければ良品の画像)
B2 モデル構築	ラベル付けミス	<ul style="list-style-type: none">不良品・良品の分類を間違ってしまった(例:不良品を複数角度から同時撮影した画像の中に、不良部位が写っているものと写っていないものが混在した。それらを分類せずに一括で不良として登録してしまった)検査員が目視検査をして良品と判断した製品が実は不良品だったが、それに気付かず良品として学習させてしまった
	学習させた不良品把握のミス	<ul style="list-style-type: none">どの種類の不良を何個ずつ学習させたのか管理をしておらず、不良品の学習が不十分になった

- 
- 概要
 - 導入工程
 - 全体像
 - 企画
 - モデル構築
 - 導入・運用
 - 相談窓口・利用可能な支援策

企画から導入・運用までの導入工程全体像

■ 本章で説明する工程



A1 【導入範囲決定】改善点の把握: 検品について改善したい点を正しく把握し、AI導入の必要性があることを確認

よくある検品に関する困りごと(例)

検査員の負担過多

- 長時間の検査による身体的疲労、およびそれに起因する不良品見逃しが発生している
- 不良品混入に関する精神的プレッシャーが大きい

検査員の不足

- 新しい検査員がなかなか採用できない
- 検査員の高齢化が進んでいる
- 検査員の離職率が高い

検査に要する工数の増加

- 仕入れ先の検査がずさんなため、安価な製品も全数検査をせざるを得ない
- クレーム対応コスト(例: 着払い負担、対応人件費)が商品販売価格を上回っている

自社の評判維持

- 顧客からの信頼維持のため、不良品率を下げたい

コロナ対策

- 三密回避のため検査の自動化を進めたい

困りごとの実態を把握

● 検査時間: XX時間/月

● 検査員へのヒアリング

● 離職率: XX%

● 検査数: XX個/月

● クレーム対応コスト: XX円

● 販売単価: XX円

● 不良品混入率: XX%

A1 【導入範囲決定】対象製品の決定(1/2): AIを活用して検査を行う対象の優先順位づけを行い、選定

対象製品選定の軸

✓ AI導入によって効果が見込めるか

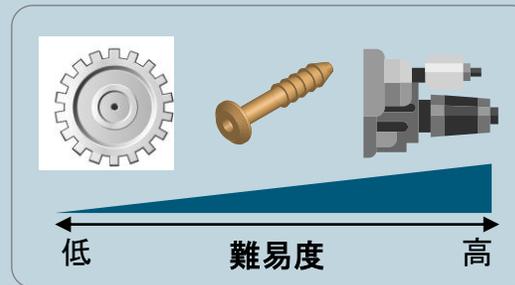


- 検査にかかる時間(例: 月当たり検品個数×1個当たり検査時間)が他製品と比較しても長い
- 今後も受注が継続する見込みがある
- 他製品へも展開可能性のある形状・材質である(他製品と比べ特殊過ぎる特徴を持っていない)

✓ AI導入が技術的に可能か



- 製品の形状が簡易(例: 立体か平面か。立体よりも平面、立体の場合は検査すべき箇所が入り組んでいない方が難易度が低い)
- 不良箇所が画像に写りやすい(例: 反射が少ない材質)
- 不良品率が一定程度(目安として不良の種類毎に2~5個以上、計20個以上¹⁾)あり、不良品が用意可能
→ 満たさない場合は外観検査AI導入ガイドブック(部品、良品のみ)を参照



関連する導入方法の工夫

工夫あ 導入工程における機械自動化度合い(検査のための撮影に常に人手を要するか)に応じた工夫

工夫い 製品の撮影方法の工夫(どのような機材を使って撮影するか)

1. あくまでも本ガイドブック(不良品が収集できる場合)を参照すべきかの判断基準であり、理想的には不良品の種類ごとに20個の製品を用意できることが望ましい(P.38参照)

A1

【導入範囲決定】対象製品の決定(2/2): 候補製品比較の例

■ 導入対象製品
□ 他候補より優位な特徴

AI導入によって効果が見込めるか

月当たり検査時間 \ominus 1個当たり検査時間 \otimes 月間生産数
受注継続見込み 他製品との形状・材質の比較

製品ID	月当たり検査時間	1個当たり検査時間	月間生産数	受注継続見込み	他製品との形状・材質の比較
AB12-C3DE	28時間	5秒	20,000個	あり	類似の製品多数あり
AC56-F5GH	8時間	15秒	2,000個	あり	類似の製品多数あり
AC57-I45	11時間	10秒	4,000個	不明	類似の材質の製品は限定的
AC57-J46	83時間	30秒	10,000個	なし	類似の材質の製品は限定的
BG23J-G5NF	7時間	90秒	800個	あり	他製品より極端に複雑な形状

AI導入が技術的に可能か

形状・材質 不良の特徴 学習に使える不良品数
現状手元にある数 + 1ヵ月で手に入り得る
 \ominus 現状の保有個数 \oplus 不良品率 \otimes 月間生産数

形状・材質	不良の特徴	学習に使える不良品数 現状手元にある数 + 1ヵ月で手に入り得る	現状の保有個数	不良品率	月間生産数
円盤状で平面	・スレ・傷 ・傷が微小(顕微鏡で検査)	16個	10個	0.03%	20,000個
筒状の立体(中が空洞)	・スレ・傷・焼け	1個	0個	0.05%	2,000個
キャップ状の立体 反射素材	・傷・加工忘れ ・反射素材のため見づらい	8個	5個	0.07%	4,000個
筒状の立体(中が空洞) 反射素材	・スレ・傷・加工忘れ ・反射素材のため見づらい	25個	15個	0.1%	10,000個
直方体で、入り組んだ凹凸の形状	・欠け・傷・ズレ ・凹凸部分にも発生	1個	1個	0.02%	800個

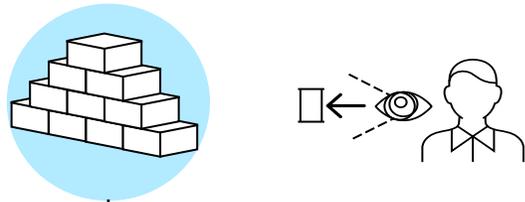
A1 【導入範囲決定】導入後の工程再設計(1/6): 検査工程再設計における人とAIの協働の考え方

導入による機械と人の協働例

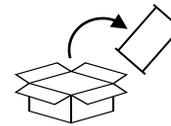
良品・不良品の判断

製品を仕分ける作業

導入前 1,000個をすべて人が判断



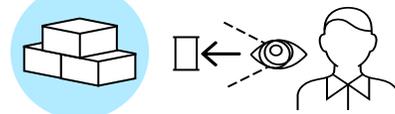
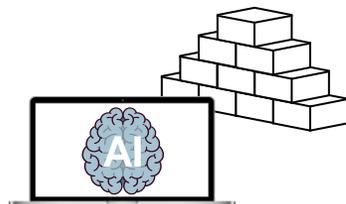
検査員が手で箱から取り出し、仕分けする作業は変わらない(ロボットの活用も可能だが、費用は高くなる)



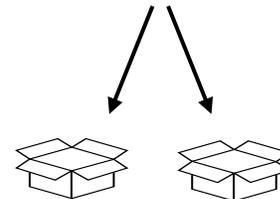
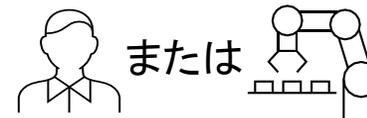
AIはあくまで「人間の脳(=判断)」の役割を一部代替できる存在。脳からの信号を受けて動く「腕」の役割は、人手やロボットで行う必要がある
(例: 製品を撮影位置に設置、良品を包装)



導入後 1,000個のうち、不良品の可能性が高い30%をAIが判断



30%のみ
検査員が目視検査



AIの導入によってすべてが自動化されるわけではないため、費用対効果が最大化されるよう、人とAIを組み合わせさせた最適な工程の設計が重要

● AI導入による変化

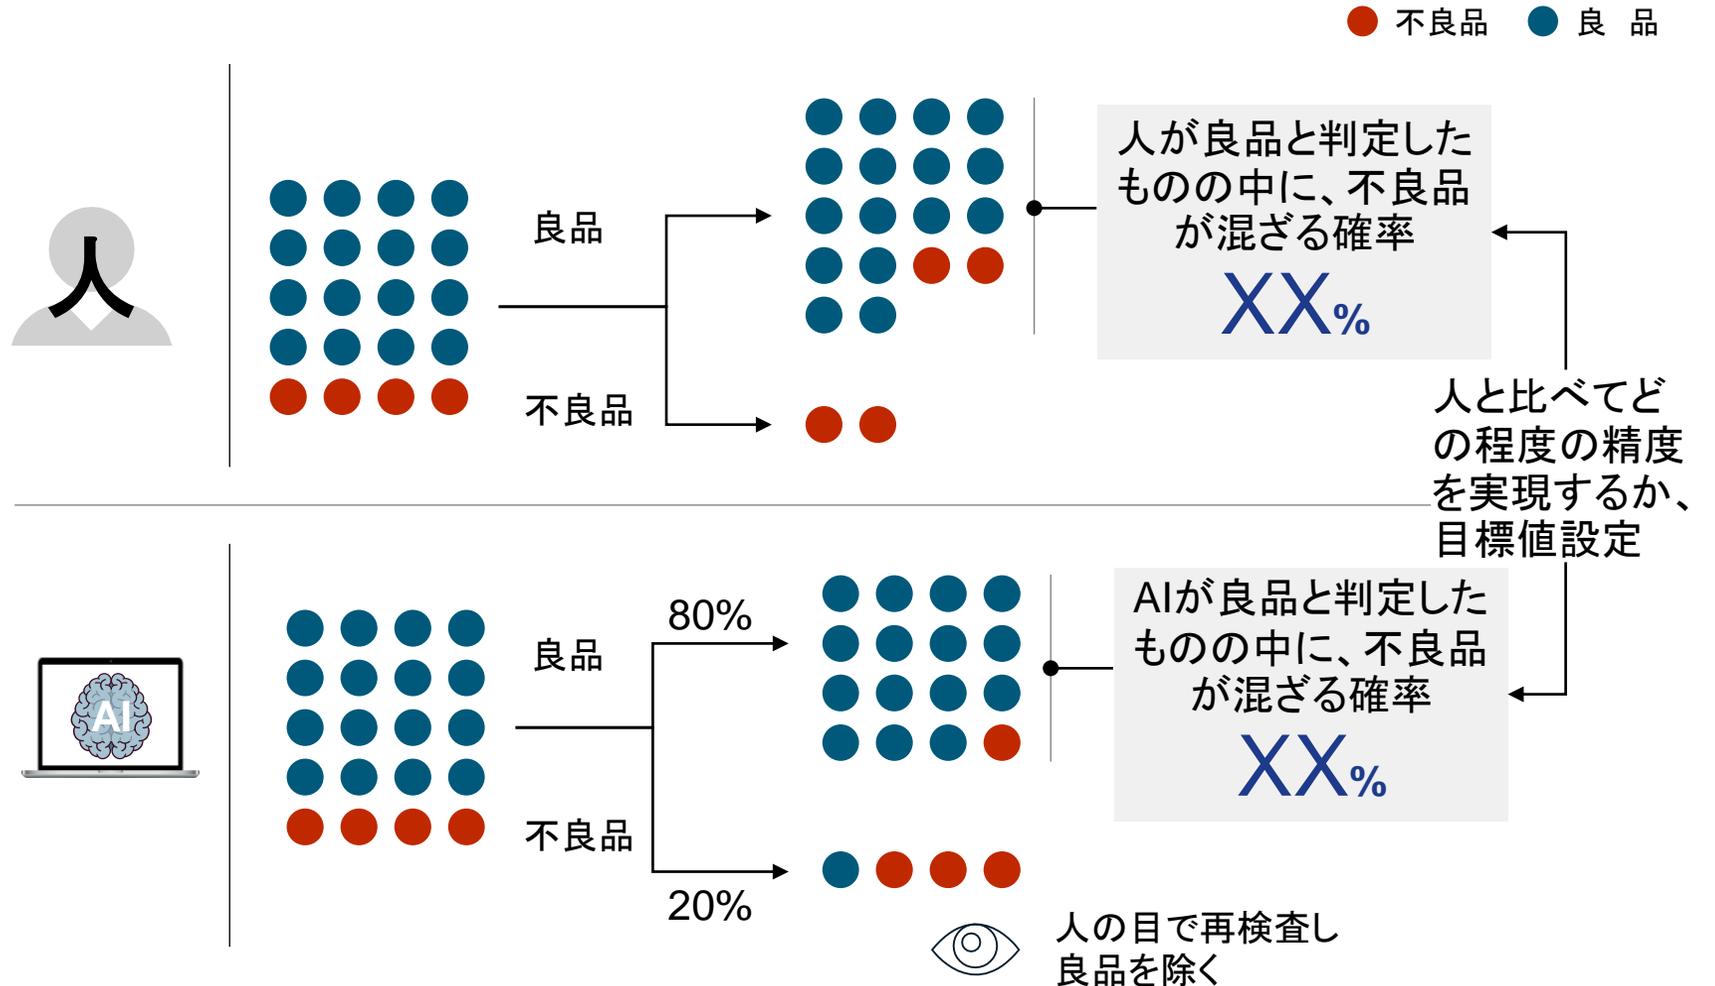
A1 【導入範囲決定】導入後の工程再設計(2/6): 人の検査精度を算出し、目指すべきAIの精度を算出

AIが検品した製品は、
80%の「良品」判定と
20%の「不良品」判定に
分けられる¹

80%の「良品」判定製品
内に不良品が混ざる確
率を0%にすることは不
可能



人の精度や検査条件²を
基に、目指すAIの精度
を設定



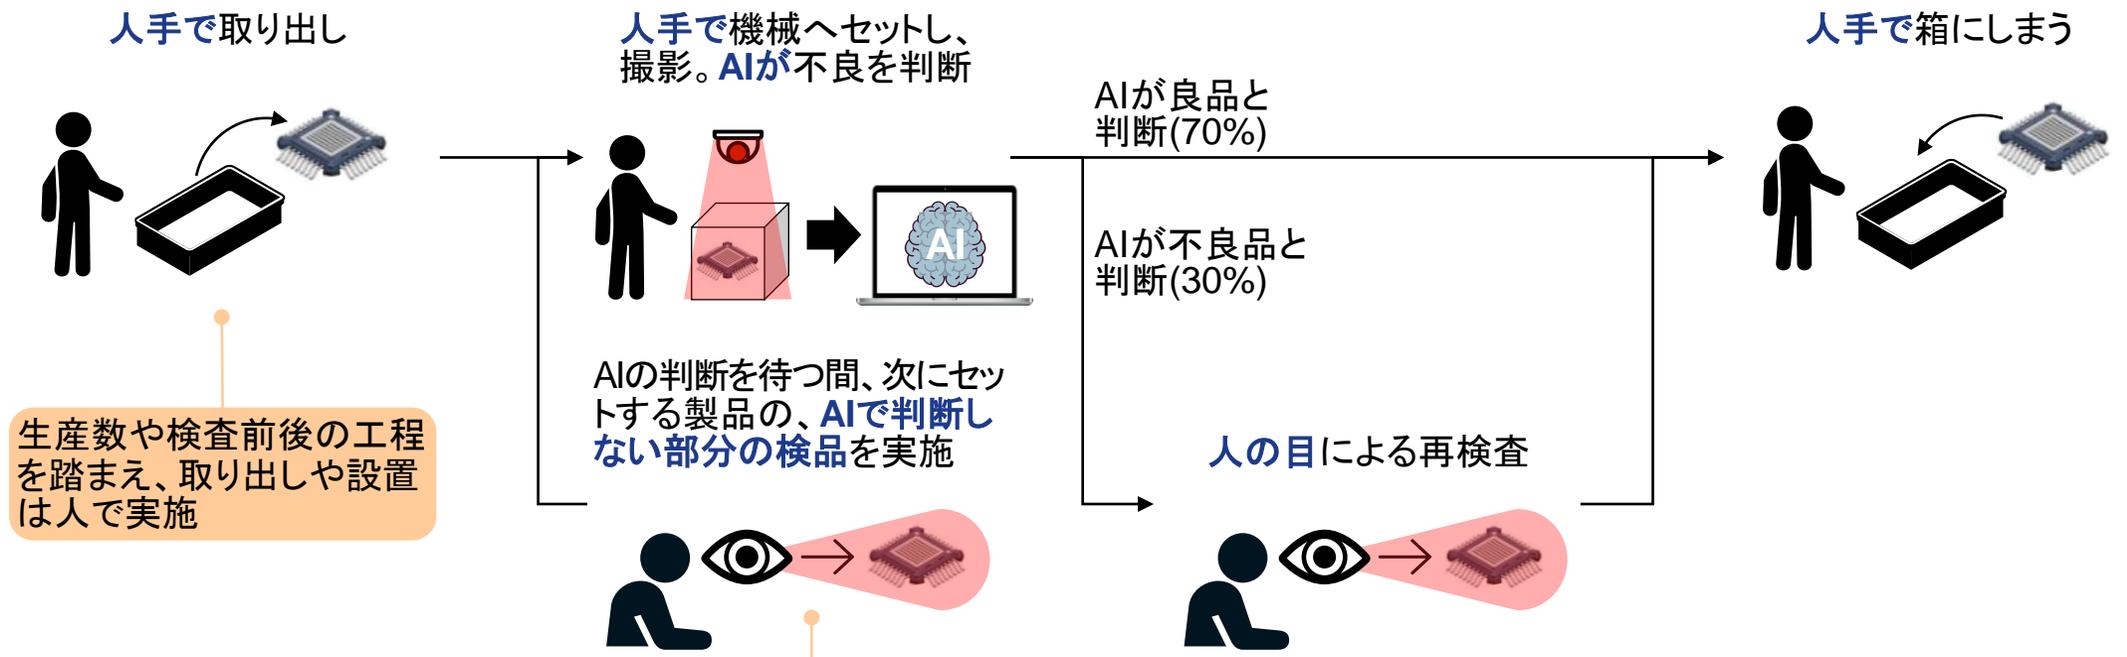
1. 不良品発生率が、1%に満たない程度の一般的な比率の場合

2. 例えば検査数が多く人では対応できない場合や、多少不良品が混じっても全数検査やり直しにはならない場合などは多少人より精度が落ちてでも許容するという判断も可能

- あ1 製品の配置を人手で実施
- あ2 製品の配置を機械で実施

A1 【導入範囲決定】導入後の工程再設計(3/6): 検品工程再設計の例【機械自動化度が低い事例】

設計の考え方



生産数や検査前後の工程を踏まえ、取り出しや設置は人で実施

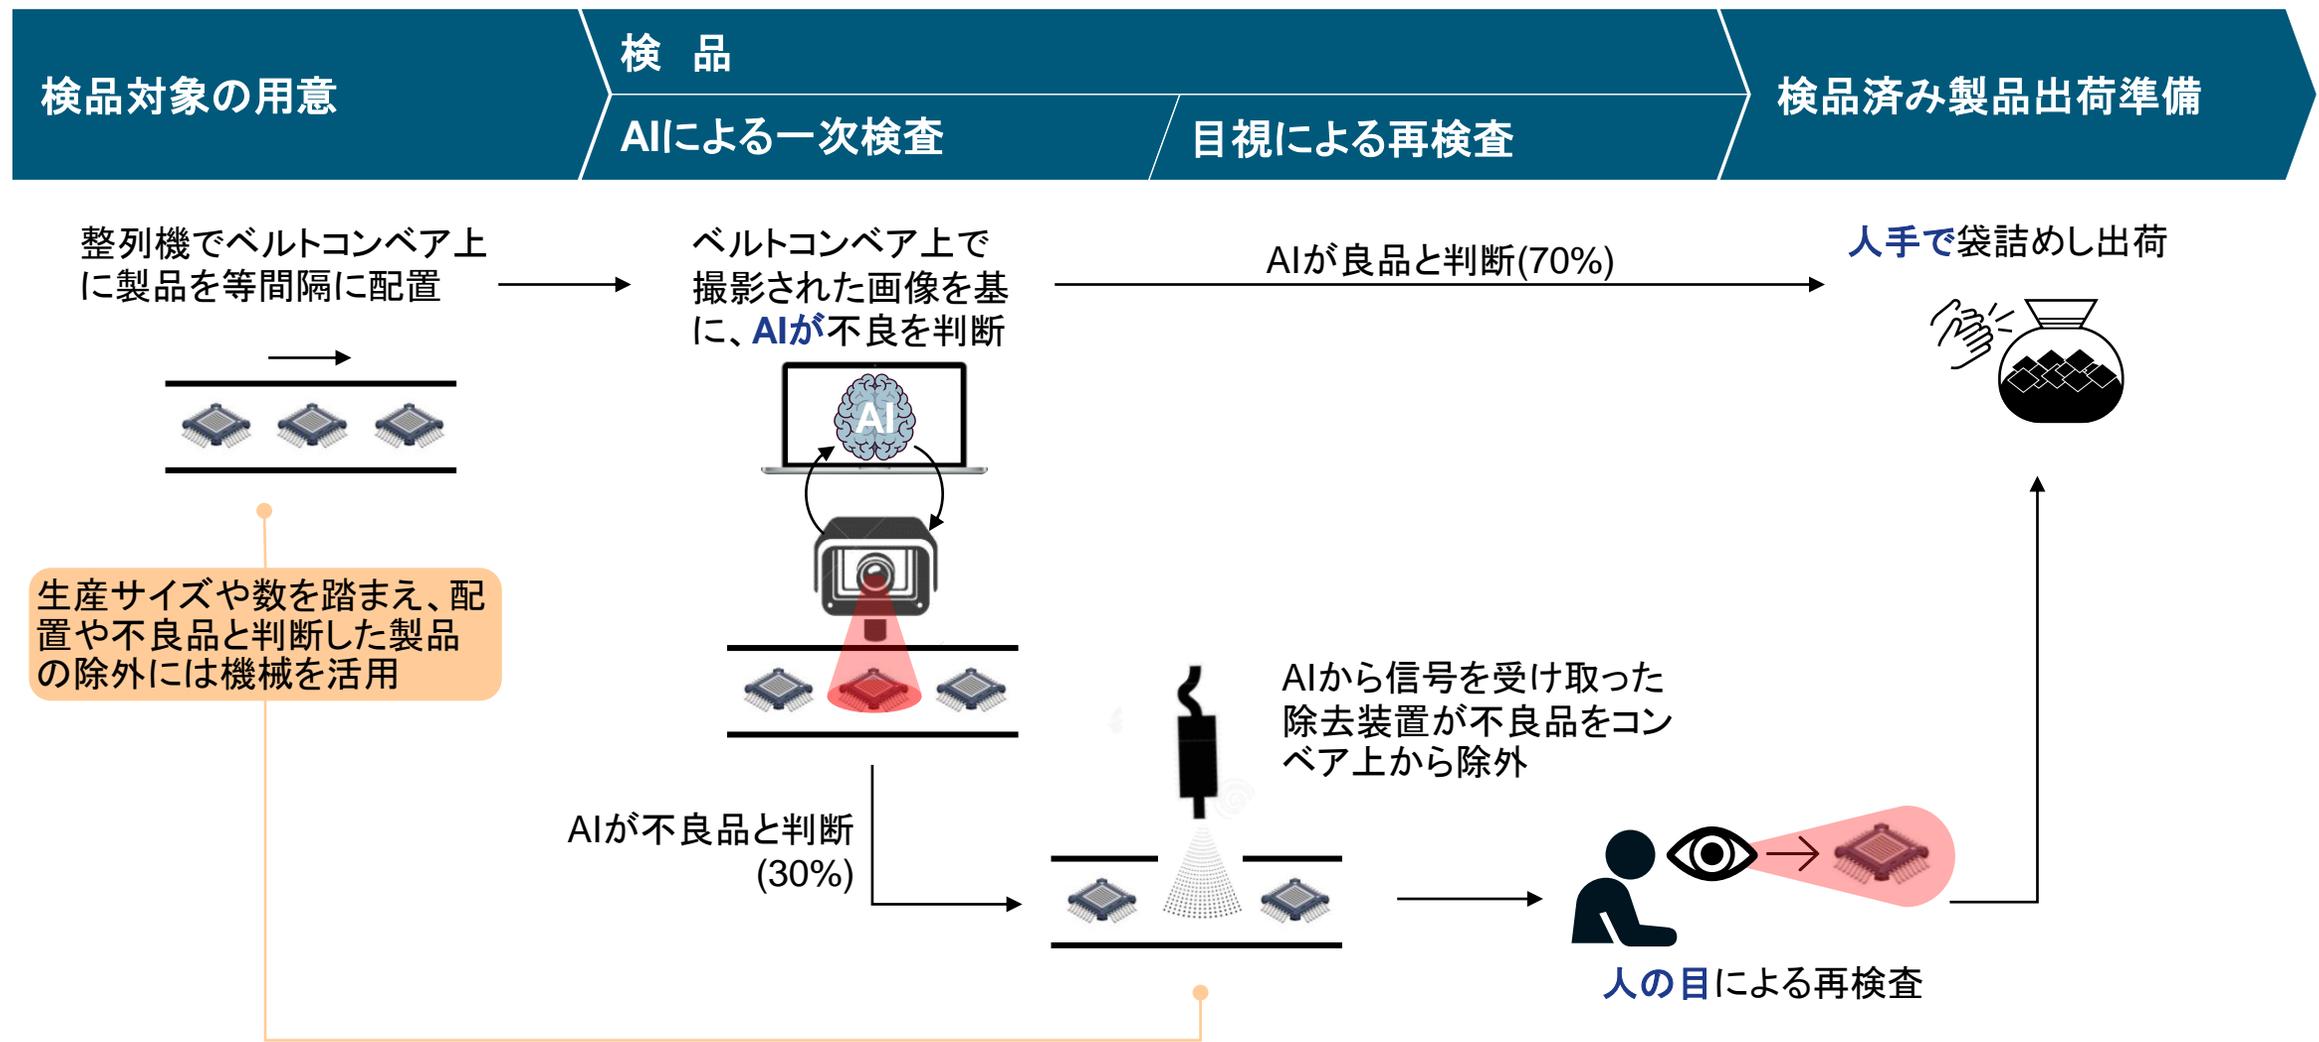
AIの判断を待つ間、次にセットする製品の、AIで判断しない部分の検品を実施

製品形状が複雑なため、特に検査が辛い・撮影がしやすい部分を優先してAIで判断。それ以外の部分(例: 撮影のために製品の角度や光の当て方を微調整する必要がある部分)は目視検査を継続

- あ1 製品の配置を手で実施
- あ2 製品の配置を機械で実施

A1 【導入範囲決定】導入後の工程再設計(4/6): 検品工程再設計の例【機械自動化度が高い事例】

設計の考え方



A1 【導入範囲決定】導入後の工程再設計(6/6): 検査時間削減等、AI活用による定量的効果を試算

試算手順

- 現在、対象製品の検品に要する時間を計算
- AI導入後の工程で検品に要する時間を試算
- 現在の検品時間と、AI導入後の検品時間を比較

試算例

■ AI導入による変化

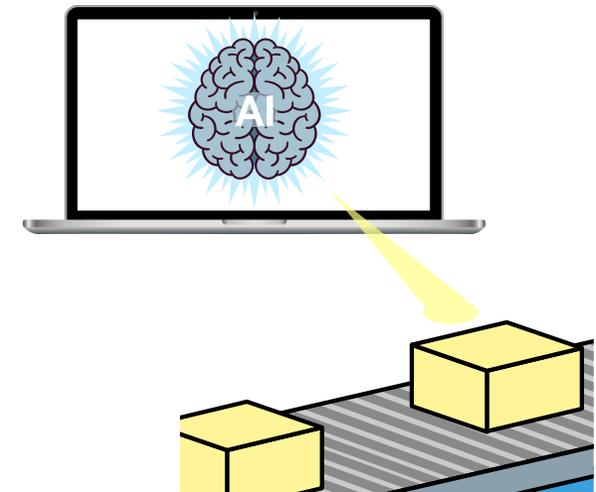
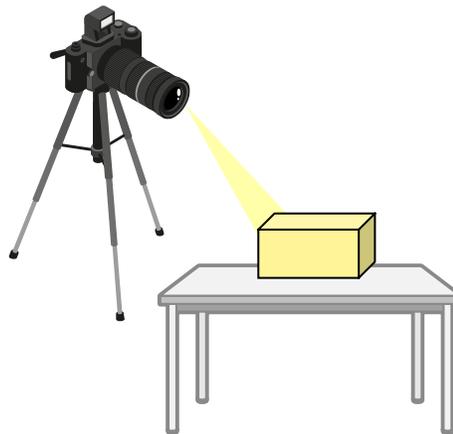
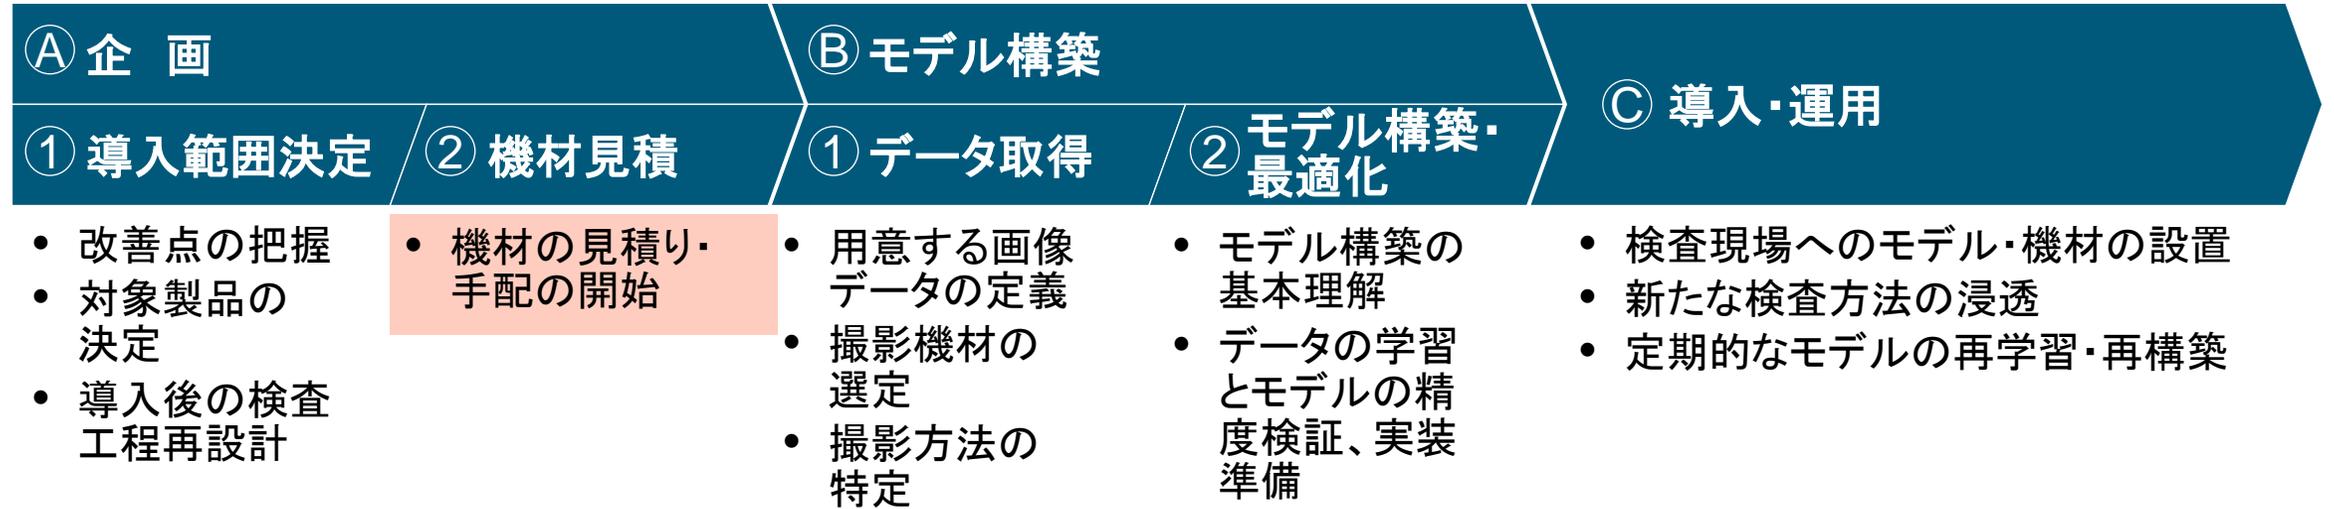


1. 60分検査+10分休憩と仮定

2. AIによる検査中に目視で検査の必要な一部の検査を終えているため、30秒かからない

企画から導入・運用までの導入工程全体像

■ 本章で説明する工程



A2【機材見積もり】導入必要な機材の用途を見つけ、費用概算を見積もり

費用項目	導入初心者向け	経験者向け	備考	
AI構築 環境機材	パソコン	8万円～		比較的新しいパソコン(目安は3年以内)を活用できる場合は0円
	GUIサービス (アカウント)	GUIサービスの一例	アカウント開設：無料 モデル構築：1万円程度 使用：8時間で約1,000円	利用サービスによって料金体系は異なる
撮影用機材	照明	3,000～5,000円(市販の照明)	2万円～(産業用)	まずは保有している照明(例:卓上ライト)で試すことも可能
	カメラ	3,000～2万円(ウェブカメラ)	8万円～(産業用)	非国産の安価なカメラであれば、1万円以下で購入可能
	カメラ固定器具	3,000～1万円(市販の三脚等)	2.5万円～(産業用)	—
	撮影背景	～1,000円		簡易的には画用紙等で試すことも可能
合計	10万円～		20万円～	※AI導入を社内で行った場合の費用。一部の工程(例:導入用機材の作成、モデル構築)を外注する場合には追加費用が発生

導入用機材
(導入事例における例)

あ2 撮影のための製品の配置を機械で実施

整列機 : 0円¹
 ベルトコンベア : 10万円
 不良品除外装置 : 1.5万円×2
 台 : 2万円
 固定器具 : 5万円

い2 撮影角度の微調整が必要

ターンテーブル : 2.2万円×2
 骨組み : 0.5万円×2
 遮光布 : 0.5万円

導入用機材は既存機材の活用や内製等、用意する方法の選択肢が広く、状況により費用が大きく変動

1. 別製品で使用していた整列機を利活用。元値は約50万円

A2 【機材見積もり】 試作品の作成により、多大な費用・労力をかけずに撮影・導入用機材のイメージ、実現可能性の把握、見積もりが可能

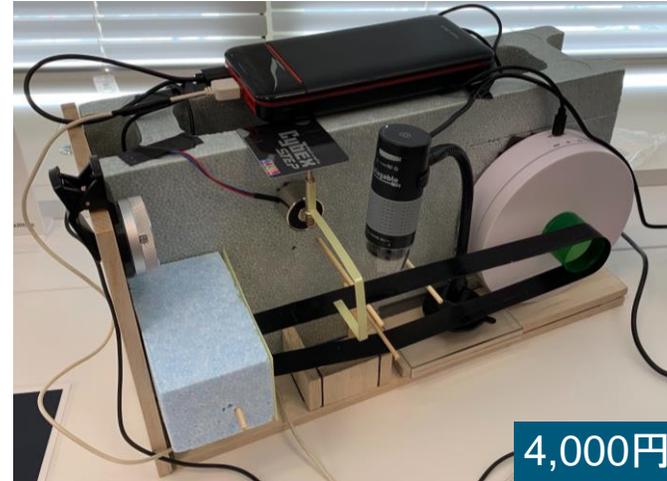
XX円 材料費¹

企画工程で撮影方法を詳細に設計しておくことで、その先の工程での手戻りを最小化

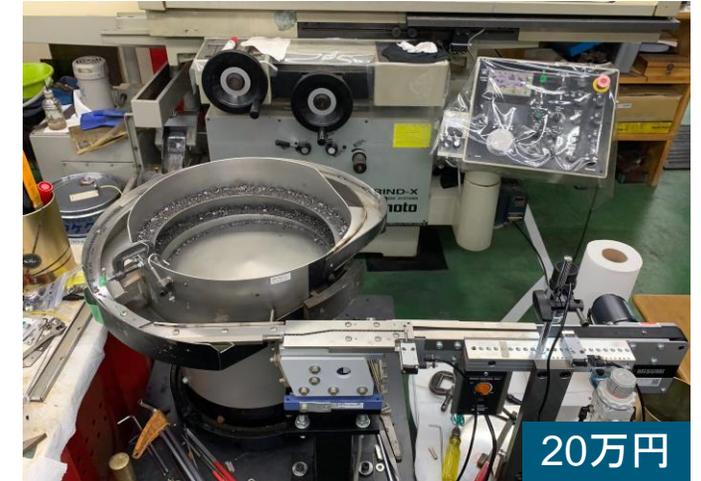
100円ショップやネット上で調達できる安価な材料を用いて試作品を作成することで、その後のAI導入のイメージもより掴みやすくなる

導入事例A

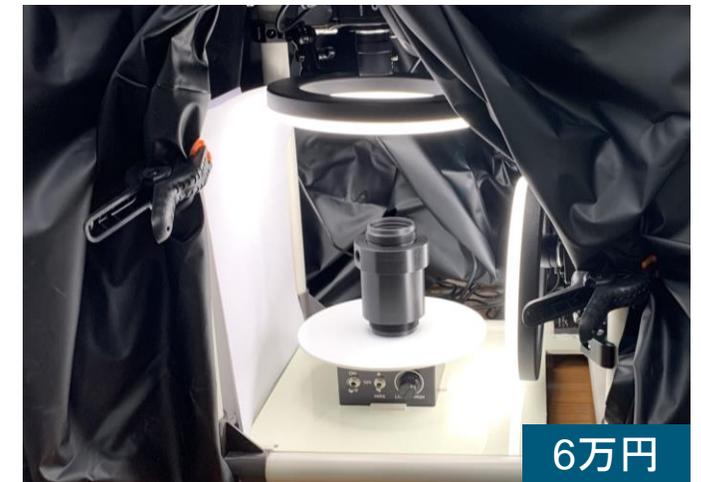
試作品



実際の機材



導入事例B



1. 導入にそのまま用いたカメラ等の費用は試作品からは除き、実際の機材に含む

A 【導入範囲決定】「企画」工程チェックシート(1/2)

の特定
困りごと

検品に関する困りごと(P.22参照)

- 検査員の負担過多
- 検査員の不足
- 検査関連のコスト高
- 自社の評判(不良品混入率)
- コロナ対策
- その他()

困りごとの実態把握(P.22参照)

検査時間 ()時間/月
離職率 ()%
不良品混入率()%

クレーム対応コスト()円
販売単価()円

導入後
工程の設計

導入製品の選定(P.23,24参照)

製品番号

製品イラスト

工程の分岐の確認(P.17)

あ: 機械化自動化度合い 1 ・ 2
い: 撮影方法の工夫 1 ・ 2

AI導入後の検品工程の設計(P.25~29参照)

取り出し・
撮影機器
への設定
設置方法

画像撮影・AI
の判断
AIの待ち時間
に目視
検査する部位

AIが不良品
と判断
()%
AIが良品と
判断
()%

人による
再検査

出荷準備

の試算
効果とコスト

想定効果(P.30参照)

定量的効果

目視検査数が %減
(検査員 人 × 日 →
検査員 人 × 日)

新規 名 の雇用が不要に
(給与が 名 で年間約 万)

定性的効果

- 従業員満足度の向上(検査員の負担減少、より創造的な業務への転換)
- 技術継承の促進・若手の育成
- 人材の採用・ひきつけ
- その他 ()

想定費用(P.32参照)

導入費用約()万円
維持費用 ()円/月

↑ 効果とコストを比較し、導入を進めるか判断 ↓

A 【導入範囲決定】「企画」工程チェックシート(2/2):記入例

の特定
困りごと

検品に関する困りごと(P.22参照)

- 検査員の負担過多
- 検査員の不足
- 検査関連のコスト高
- 自社の評判(不良品混入率)
- コロナ対策
- その他()

困りごとの実態把握(P.22参照)

検査時間 (448)時間/月
 離職率 ()%
 不良品混入率(0.05~0.03)%

クレーム対応コスト()円
 販売単価()円

導入後
工程の設計

導入製品の選定(P.23,24参照)

製品番号

AB123-C56DE

製品イラスト



AI導入後の検品工程の設計(P.25~29参照)

取り出し・
撮影機器
への設定

画像撮影・AI
の判断

AIの待ち時間
に目視
検査する部位

設置方法

人手

製品内部

AIが不良品
と判断
(20 %)

AIが良品と
判断
(80 %)

人による
再検査

出荷準備

工程の分岐の確認(P.16)

あ: 機械化自動化度合い ① ・ 2
 い: 撮影方法の工夫 1 ・ ②

想定効果(P.30参照)

定量的効果

目視検査数が 75 %減
 (検査員 4 人 × 14 日 →
 検査員 4 人 × 3.5 日)

新規 2 名の雇用が不要に
 (給与が 2 名で年間約 400 万)

定性的効果

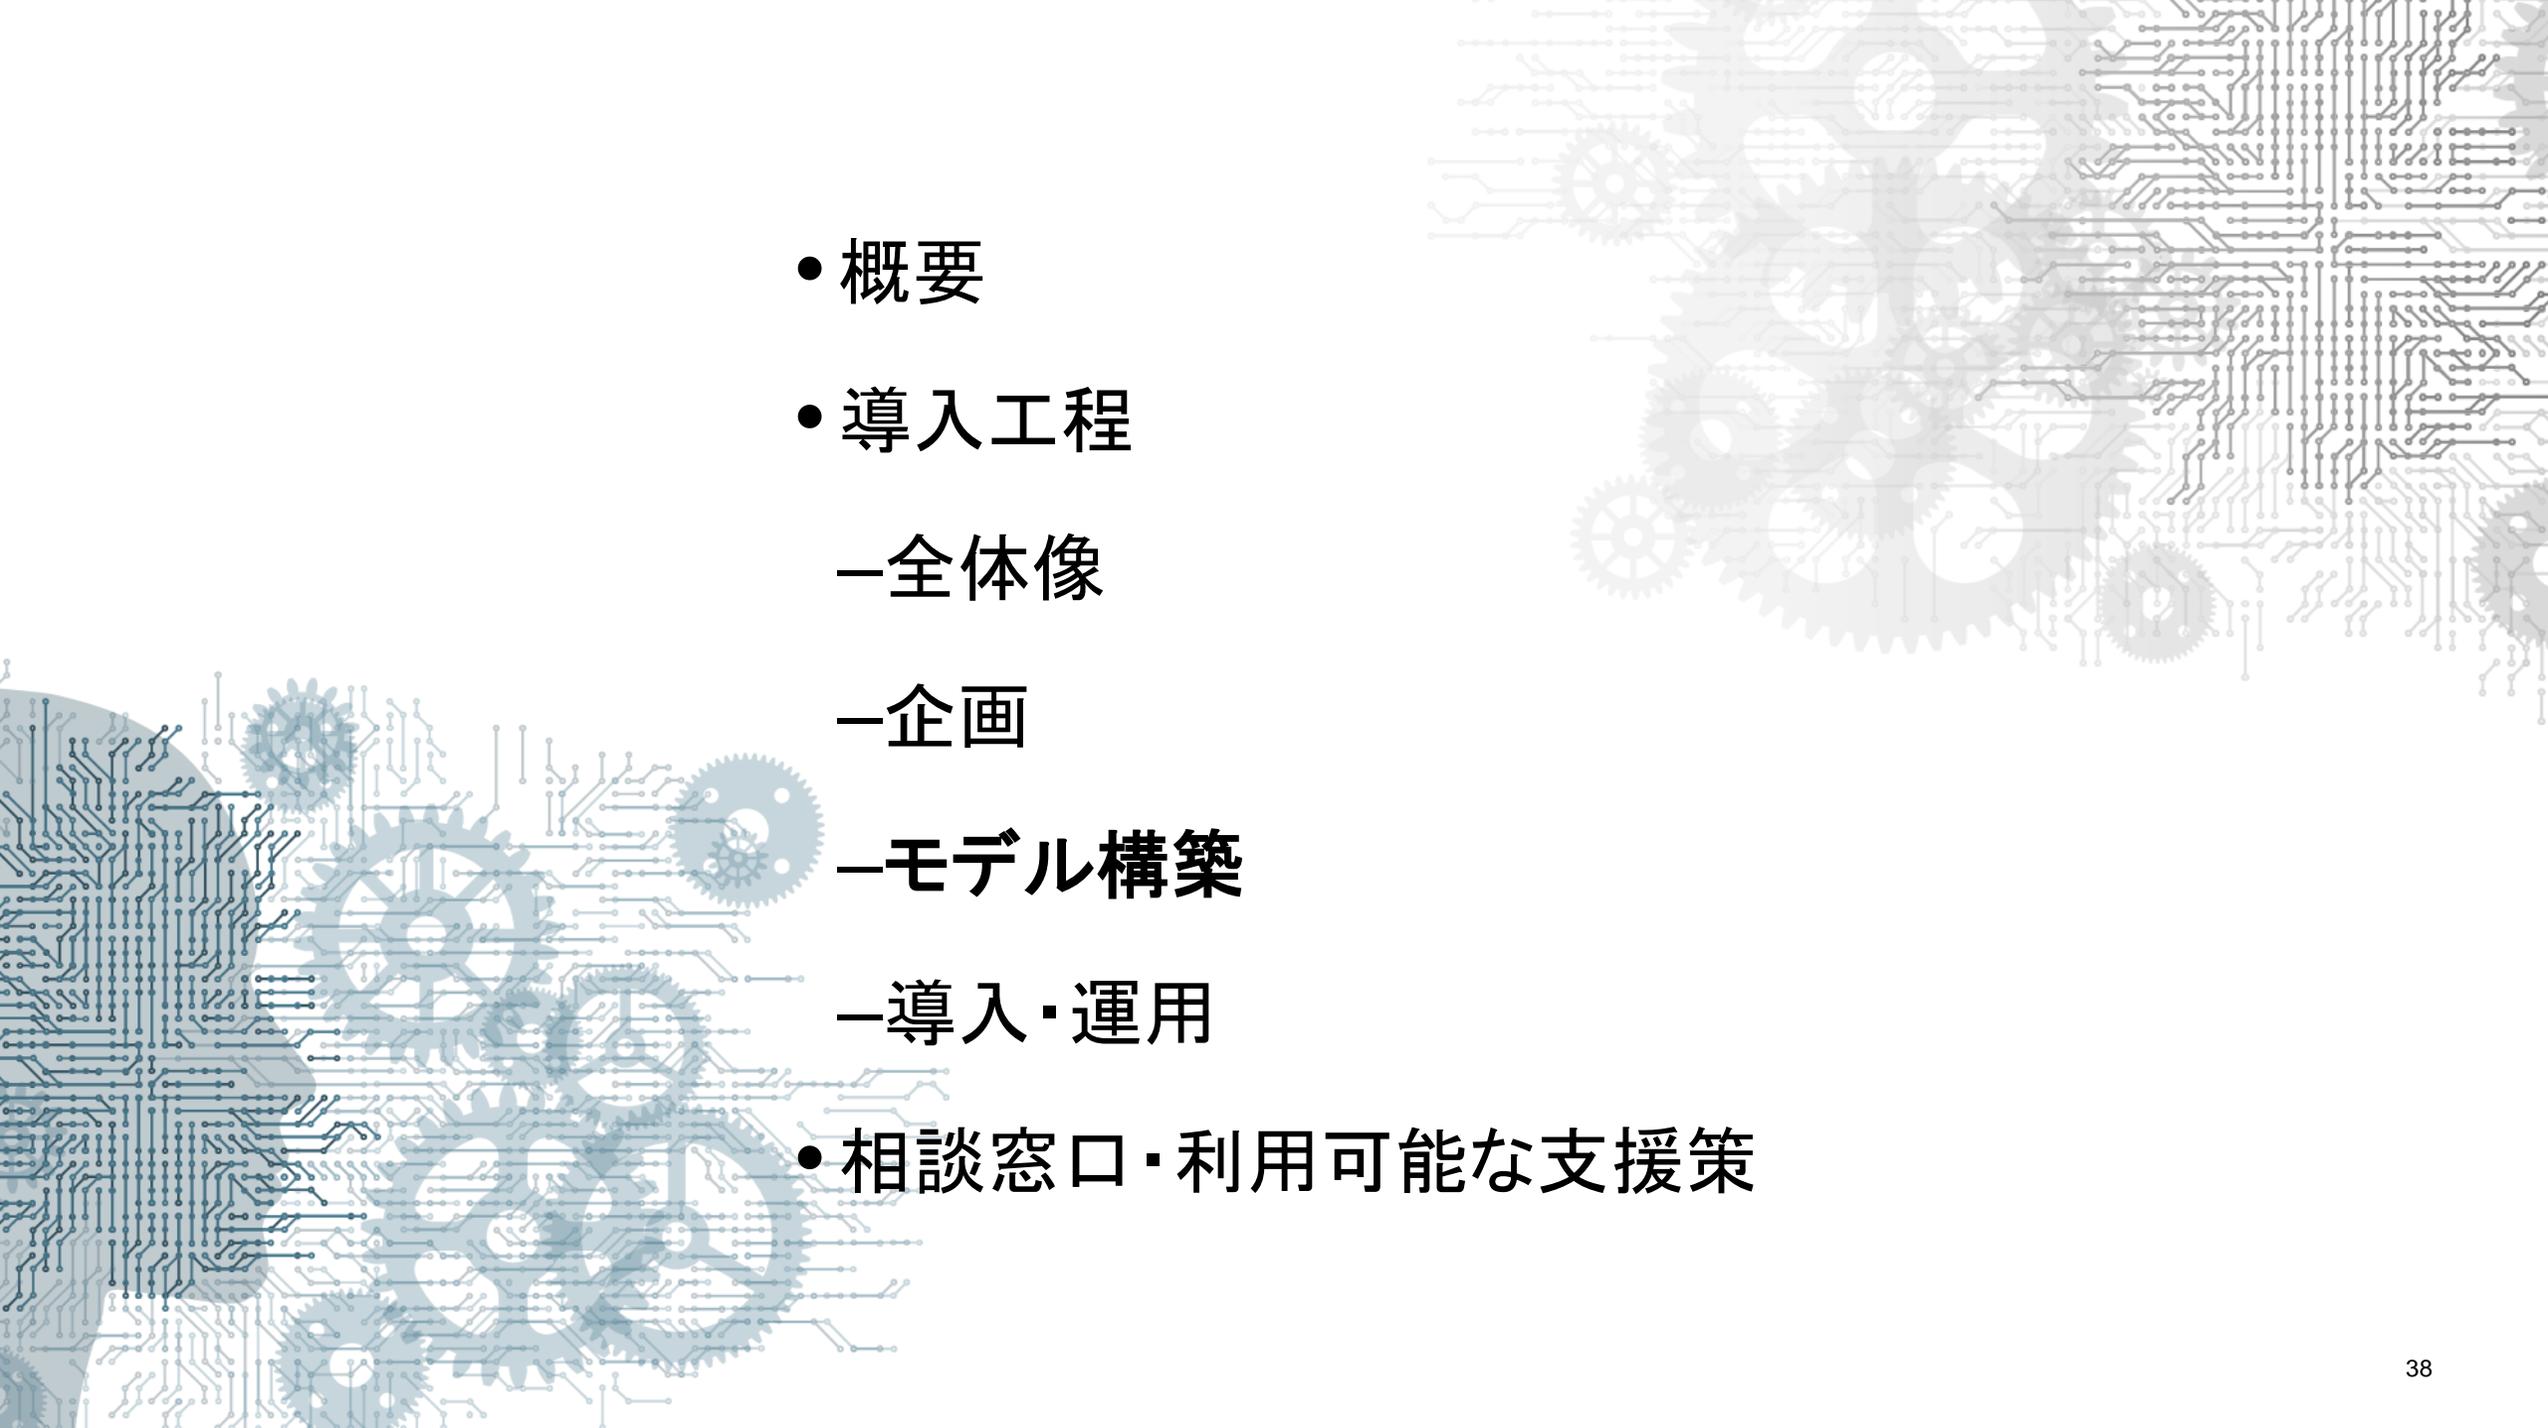
- 従業員満足度の向上(検査員の負担減少、より創造的な業務への転換)
- 技術継承の促進・若手の育成
- 人材の採用・ひきつけ
- その他()

想定費用(P.32参照)

導入費用約(25)万円
 維持費用 (8,000)円/月

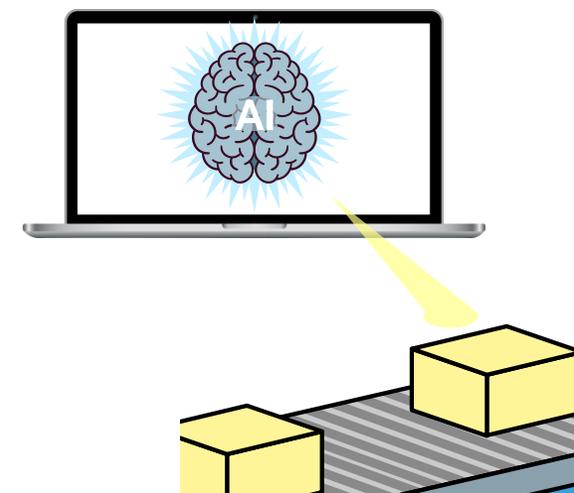
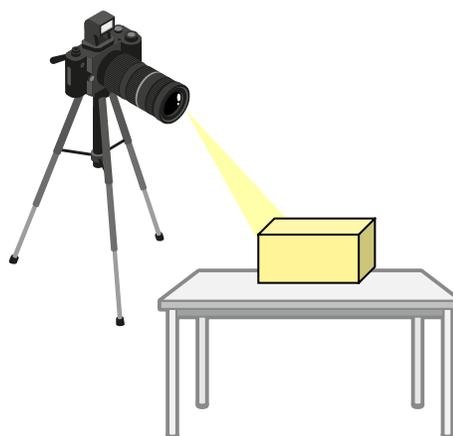
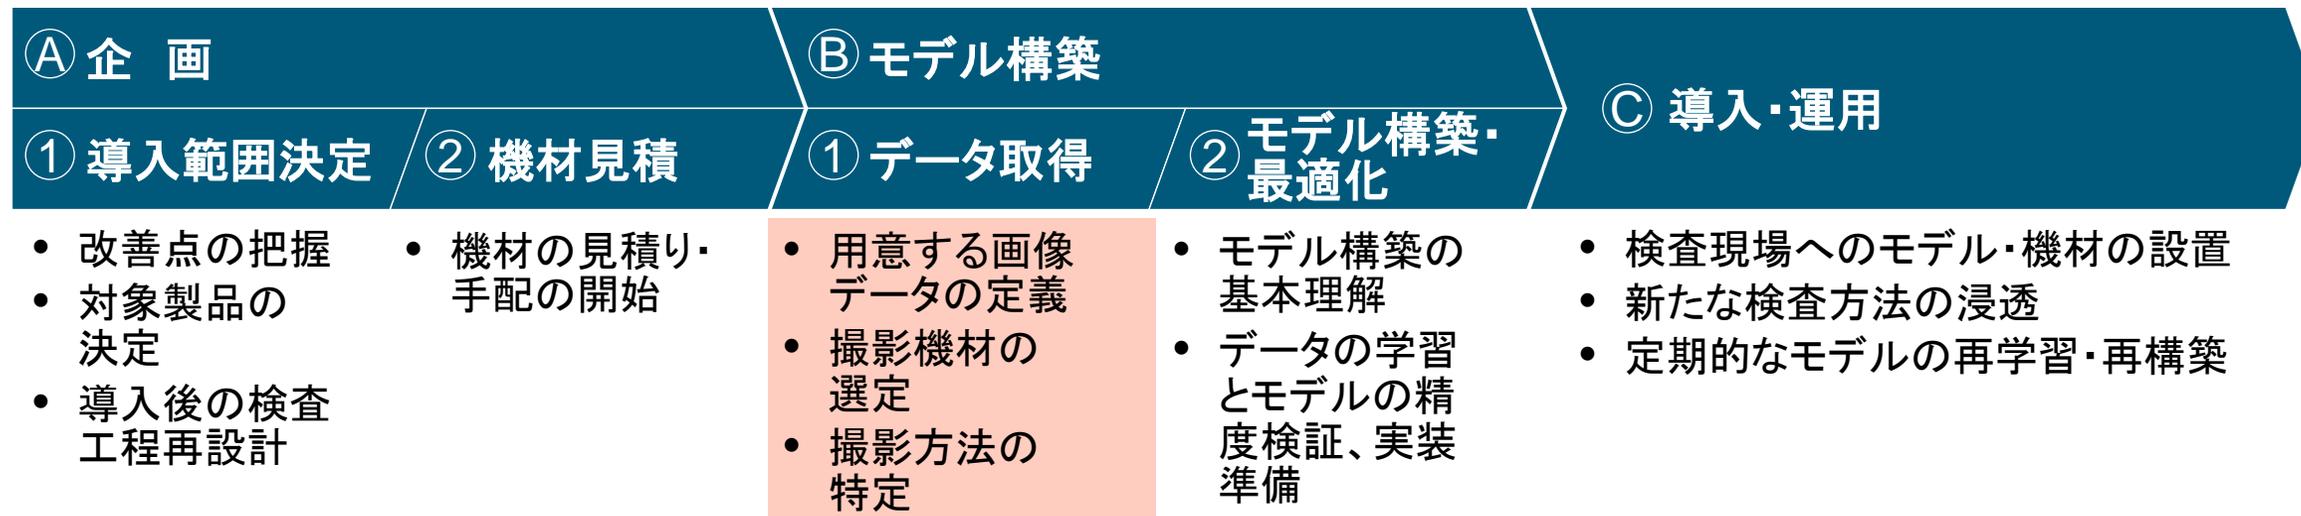
↑ 効果とコストを比較し、導入を進めるか判断 ↓

効果とコスト
の試算

- 
- 概要
 - 導入工程
 - 全体像
 - 企画
 - モデル構築**
 - 導入・運用
 - 相談窓口・利用可能な支援策

企画から導入・運用までの導入工程全体像

■ 本章で説明する工程



い1 平面のみの撮影

い2 撮影角度の微調整が必要

B1 【データ取得】用意する画像データの定義: 良品250枚以上、不良品は種類毎に100枚程度の写真を収集

データ取得の目標

モデルの学習のため、種類毎(例: 良品、欠けのある不良品)に複数枚の写真を収集

良品

- 50個の製品を準備。1製品につき5枚ずつ、最低合計250枚の写真を撮影
- ただし写真の合計数は不良品の写真合計数と合わせる

不良品

- 不良の種類(例: 欠け・穴といった不良の種類、傷の大きさ)毎に20個の製品を準備。1製品につき5枚ずつ、不良の種類毎に100枚の写真を撮影
- 不良品が目標数集まらない場合、その種類の不良品検知精度が低くなる恐れがある

撮影した画像を用いてモデルを構築した後、精度検証を行うと、精度が不十分である場合がある。その場合は原因分析と工程のやり直し(例: データ再取得)が必要(P.54参照)

取得イメージ

種類	合計写真数枚	最低限必要な製品数個	1製品につき撮る写真数枚
良品	250~ *この場合不良品と数を合わせるため500が望ましい	50~	5
不良品	欠け	100	20
	キズ	100	20
	穴	100	20
	ズレ	100	20
	サイズ違い	100	20

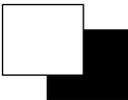
い1 平面のみの撮影の場合(例: 平らな製品)の目安

い2 撮影角度の微調整が必要(例: 曲面を回転させながら撮影)な場合5~10枚が目安¹

1. 製品の曲がり具合によって、全ての面の傷を写真で判別できるように撮影するために必要な枚数が異なる

B1

【データ取得】撮影用機材の選定(1/2): データ取得に必要な機材および選定基準一覧

機 材	選定基準
 パソコン	<ul style="list-style-type: none"> RAM 4Gb ROM 100Gb free CPU i5を推奨
 カメラ	<ul style="list-style-type: none"> 次頁参照
 カメラ固定器具	<ul style="list-style-type: none"> 角度・高さの調整可能 カメラの付属品や市販の三脚での代替可
 照 明	<ul style="list-style-type: none"> 耐久性に優れている 三脚付き、角度・高さの調整可能 色は基本白色。傷が写りにくい場合、製品の補色となる色の照明を試す
 製品を載せる台	<ul style="list-style-type: none"> 撮影方法によって異なる ① 平面撮影の場合は机等で代替可 ② 製品を回転させて撮影する場合、ターンテーブル等が必要 (自動回転・速度調整可能なもの)
 撮影の背景	<ul style="list-style-type: none"> 製品と明確に異なる色 光が反射しづらい素材

B1 【データ取得】撮影用機材の選定(2/2): カメラの選定方法詳細

カメラの選定方針

カメラは安価なウェブカメラから試す

カメラはウェブカメラと産業用カメラに大別される¹

- ウェブカメラはレンズ内蔵・安価・低スペック
- 産業用カメラはレンズ別・高価・高スペック

安価なウェブカメラから試し、傷が鮮明に映らない場合によりスペックの高いカメラを検討する

必要な仕様の特定には無料レンタルや問い合わせ窓口も活用可能

製品の形状や材質によって、照明の種類や光の当て方も含め選定が難しい場合には、種類無料レンタルや相談窓口を活用

- レンタル: 工業用カメラ等を数週間無料で借りられるメーカーも存在(送料負担等あり)
- 相談窓口: メーカー等が有する施設に製品を持ち込み、適切なカメラや照明の仕様を診断してもらうことが可能(有料の場合あり)

最低限必要なスペック目安



カラー・モノクロ カラーが好ましいが、傷が写る場合モノクロでも良い

画素数 目視検査を行っている場合、500万画素

フレームレート 30fps以上

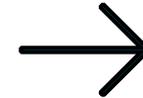
動作環境 Windows8以降



焦点距離 10cm程度の製品であれば、焦点距離は25mm程度

1. ウェブカメラは、撮影された映像にリアルタイムでアクセスできるカメラのこと。一方産業用カメラは、産業用途を想定したカメラを指すため、厳密には産業用カメラかつウェブカメラと定義される機器もある

B1 【データ取得】撮影方法の特定(1/4): 基本の撮影環境と機材を整え、製品毎に撮影手法を工夫し、必要な条件の写真撮る



- カメラのピント、しぼり、シャッター速度を調整し、固定
- カメラと製品の位置や距離を固定
- 照明等の環境を一定にし、導入時の検査環境と同条件を整える
- 撮影時の背景の色は、製品と近い色を避ける
- 製品以外の物体を映り込ませない

工夫い

製品の撮影方法の工夫 (どのような機材を使って撮影するか)

い1 平面のみの撮影
(例: 平らな製品)

い2 撮影角度の微調整が必要
(例: 曲面を持つ製品を回転させながら撮影)

- 画像の明るさが十分
- 製品全体が適切な大きさに写っている
- 製品が統一の大きさに写っている
- 背景の色が統一されている
- 製品にあるキズ等不良個所がはっきり写っている
- 写真に製品以外のものが映っていない

B1 【データ取得】撮影方法の特定(2/4):

i 撮影環境・機材設置に関する注意点と具体的な方法例



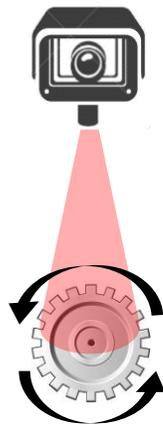
- ① カメラのピントとしぼり、シャッター速度を調整し、固定
(写真に傷がはっきりと写るよう調整)
- ② 写真内の製品の大きさを一定に保つため、カメラのズームを調整し、カメラと製品の位置や距離を固定
(写真1枚に占める製品割合が、8割程度になるように調整)
- ③ 照明等の明るさ条件を一定にする
 - ・ 窓がない部屋で実施
 - ・ 部屋の中で光の当たり方・光量を左右する要因を取り除く(例: 光を反射するものを置かない)
 - ・ 自然光の入る部屋の場合は、照明を設置した段ボールの中で撮影
- ④ 撮影時の背景色は製品と近い色や、反射する素材を避ける。製品および製品を載せる台の埃等の汚れも極力落とす
 - ・ 例: 黒い製品の場合、白い背景を用意
 - ・ 例: 白や金属製の製品の場合、黒や深緑の背景を用意
- ⑤ 製品以外の物体を映り込ませない
 - ・ 良い例: 製品を撮影台に設置
 - ・ 悪い例: 手で持って撮影(写真に指が入り込む)

AIを**実際の検品現場に導入する際と全く同じ条件**で写真を撮影

B1 【データ取得】撮影方法の特定(3/4): ii 製品の形状に応じた撮影方法の工夫

い1 平面のみの撮影の場合

例) 平らな製品



製品を水平方向に**回転させながら撮影**
(光の加減によって傷の写り具合が変わり得るため、5枚で1周回る程度を目安に、同じ面を撮影)

い2 撮影角度の微調整が必要な場合

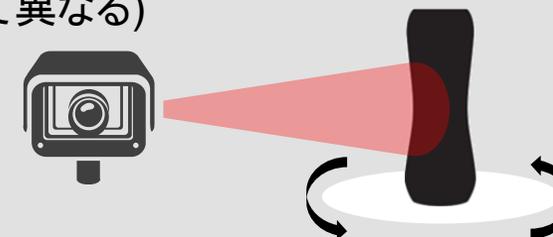
例) 曲面を持つ製品

一方向からでは撮影の難しい凹凸がある立体物

- 曲面の場合、**画面の端においても傷が写る程度にピントとズームを調整**
- カメラもしくは製品を動かす際に写真がぶれないよう、**シャッター速度と回転台の速度を調整**(例: 手のひらサイズの製品の場合1周5~10秒程度が目安)

曲面の撮影方法の一例

- 製品を回転させながら、1台のカメラで撮影
- すべての範囲がいずれかの画像に写り込むよう、網羅的に撮影(一般的には360度回転で5~10枚程度。曲面の曲がり具合によって異なる)



B1 【データ取得】撮影方法の特定(4/4):

iii 写真が正しく撮れていることを確認

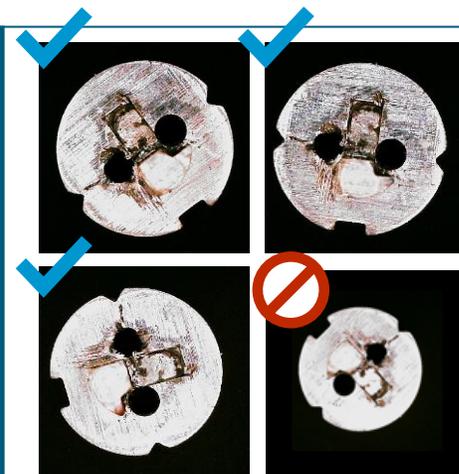
画像の明るさは十分ですか



製品全体が適切な大きさで写っていますか



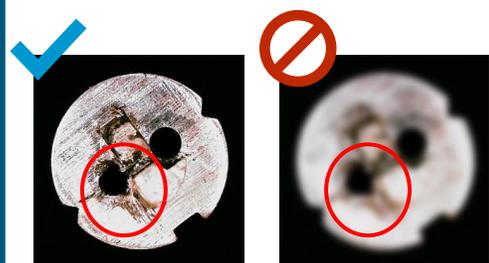
製品は同じ大きさで写っていますか (誤差1ミリ程度を目安に収める)



背景の色は統一されていますか



不良の箇所がはっきり写っていますか(肉眼でも判別できる程度)

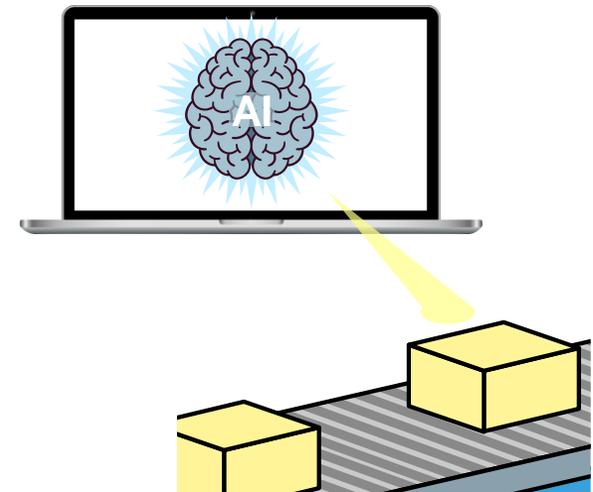
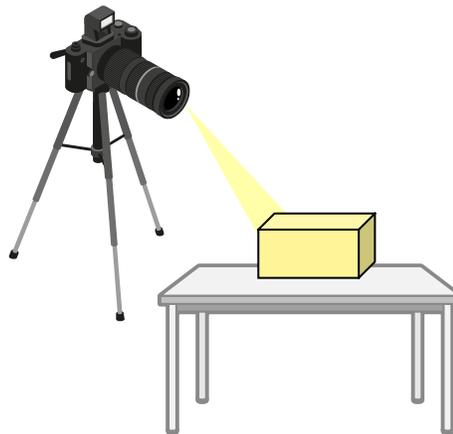
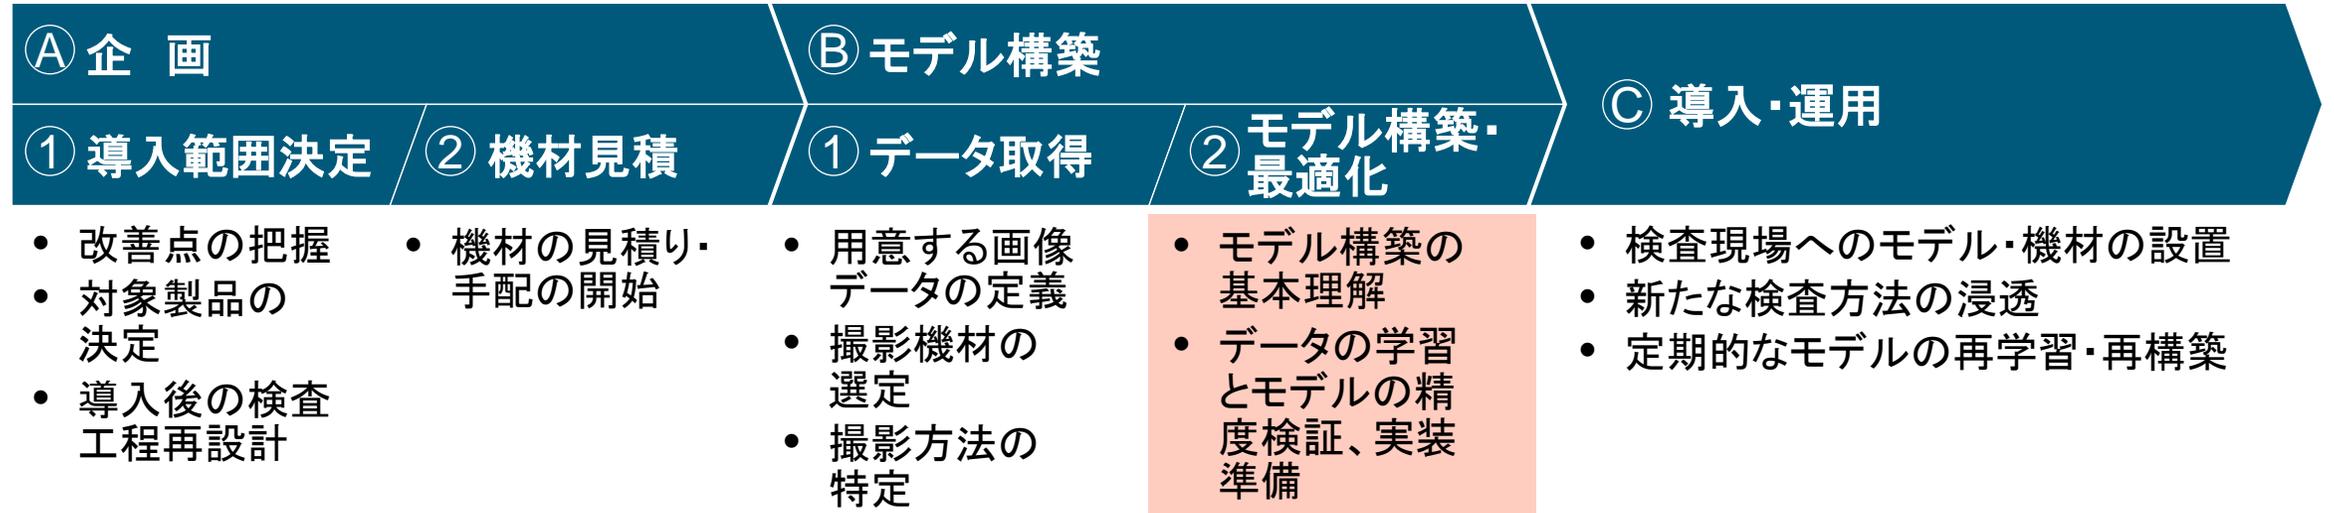


余計なものが映っていませんか (埃等の映り込みも不可)



企画から導入・運用までの導入工程全体像

■ 本章で説明する工程



B2 【モデル構築】モデル構築の基本理解(1/2): 中小企業における外観検査AIに必要なモデルの要素とモデル構築の方法

モデル構築方法

各方法の比較

プログラミング知識依存度

モデルの自由度

モデルの精度

自動モデル構築(GUI) ツールを活用した構築

学習用画像(ラベリング済)をアップロードすることで、自動的にモデル構築が完了

学習後のモデルの精度の検証や修正も、ツール上で実施可能

AI人材¹の重点支援不要

- データ収集・モデル構築にはプログラミング知識不要
- モデルを現場に実装する際には一部プログラミング知識が必要となり、AI人材の支援が必要となる可能性

カスタマイズ不可

- データ加工・モデルの構造等はすべて自動的に最適化される反面、使用者によるカスタマイズは不可

高い精度を実現可能

- 高い計算力でモデルが最適化されるため、高い精度を実現可能

自力モデル構築

プログラミングスキルを基に、モデル構築・検証、最適モデルの選定を実施

AI人材の重点支援必要

- データ収集・モデル構築・実装の各段階にプログラミング知識が必要となるため、AI人材の重点的な支援が必要

カスタマイズ可能

- モデル全体を使用者が開発するため、カスタマイズの自由度が高い

(AI人材のスキルに応じて)

高い精度を実現可能

- 使用者が適切にモデルの最適化を行うことで、高い精度を実現可能

中小企業におけるモデル構築においては、高度なプログラミング知識なしで構築・保守運用が可能であることが重要な要素

高度なプログラミング知識がなくても利用可能な自動モデル構築ツール(GUI)を活用

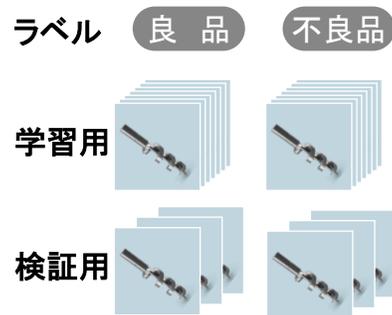
GUI=Graphical User Interfaceの略。
マウスのクリックやドラッグで操作が完結

1. プログラミングおよびモデリングのスキルを有する人材

B2 【モデル構築】モデル構築の基本理解(2/2): 一般的なモデル構築はデータ準備、モデル構築・最適化、モデル導入準備の順で進める

データ準備

- 取得した画像データにラベル(良品・不良品)情報を付与
- 画像サイズや角度等を加工し、写真を標準化¹
- 画像を学習用と検証用(7:3)に分類



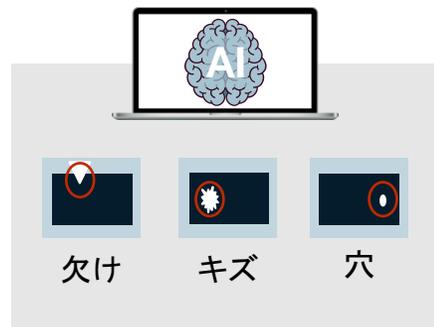
1. GUIの場合は自動で実施

モデル構築・最適化

初期モデル構築

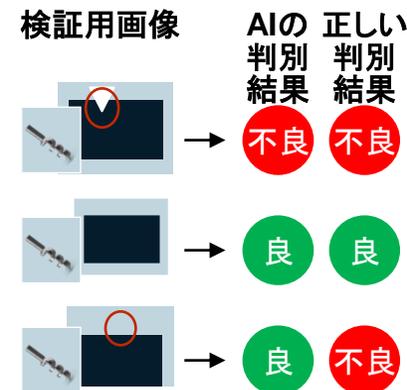
- 学習用画像を用いて、画像の特徴とラベルの関係性を学習させ、初期モデルを構築

モデルが学習した不良品の特徴



モデルの検証

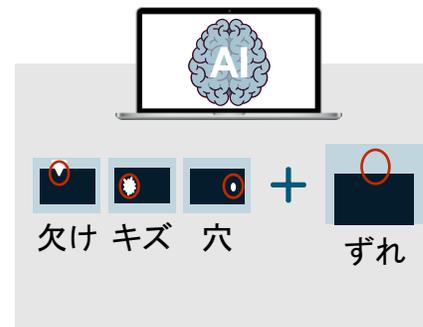
- 初期モデルに検証用画像を投入し、良品・不良品を判別
- 判別結果と真の結果を比較し、モデルの精度を評価



モデルの修正

- 追加学習用画像を用意
- 追加学習と検証を繰り返し、精度を改善

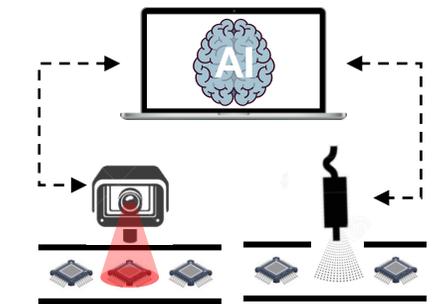
「ずれ」の特徴を追加で学習



モデル導入準備

- 現場への導入に向け、パソコン上のモデルと各機材(例: カメラ、不良品を弾く装置)を接続
- 実製品で用いてモデルの判別精度を検証し、問題がある場合は画像データを再取得

モデルと検査に用いる機材を接続



B2 【モデル構築】データの学習とモデルの精度検証、実装準備: GUIを活用したモデル構築の進め方全体像

自動モデル構築(GUI)ツール上で実施

ローカルのパソコンで実施

データ準備			モデル構築・最適化		モデル導入準備		
GUI環境の設定	画像アップロード	ラベル付け	初期モデル構築、検証と修正	モデル確定	開発環境の整備	使用モデルを指定判別閾値を設定	本番環境でのモデルの精度確認
<ul style="list-style-type: none"> 自動モデル構築ツールを開き、アカウントを作成 外観検査AIツールを選択 	<ul style="list-style-type: none"> 画像データを格納するフォルダを作成 画像データ(学習用・検証用まとめ)をフォルダにアップロード 	<ul style="list-style-type: none"> 各画像データに「良品」「不良品」のラベル付け 	<ul style="list-style-type: none"> モデル構築に用いるフォルダを指定し、モデル構築を開始 でき上がったモデルの精度を確認 精度が低い場合、画像データの追加・削除を行い再度モデルを構築 	<ul style="list-style-type: none"> 複数構築したモデルの中から最も精度の高いモデルを選択し、閾値を確認 最適モデルを自動モデル構築ツールからダウンロード 	<ul style="list-style-type: none"> コードを準備するために必要なアプリケーションをダウンロード 	<ul style="list-style-type: none"> モデルをパソコン上で動かすための」コードに、モデルの所在場所(=パス)を指定 不良品検知度合い調整のため、判別の閾値を設定(不良確率何パーセント以上の製品を不良として判別するか指定) 	<ul style="list-style-type: none"> 出来上がったモデルを使用して実際の導入と同じ条件で、製品を検品し、精度と検査時間を確認

B2 【モデル構築】データの学習とモデルの精度検証、実装準備: 基本用語の解説(1/2): 閾値

製品の実際の良否: ● 不良品 ● 良品

概念の説明: 閾値とは

一般的には
「数値的な境目」、
「境界線となる値」の意

モデル構築の文脈では
AIは、各製品について
その製品が「不良品で
ある確率」を算出する
「不良品である確率」が
何%以上の製品を「不
良品」と判断するかを決
める必要... この確率の
境界線のことを閾値と
呼ぶ

具体例

対象製品	AIが算出した 不良品である確率	モデルの判断結果	
		閾値を50%に した場合	閾値を80%に した場合
●	5%	良品	良品
●	10%	良品	良品
●	20%	良品	良品
●	70%	不良品	良品 ✖
●	90%	不良品	不良品
		全数正解	1個誤判断

不良品が良品に混
じることを極力避け
るため、閾値を低め
に設定し、不良品の
検知漏れを最小化
(詳細はP. 52参照)

B2 【モデル構築】データの学習とモデルの精度検証、実装準備 基本用語の解説(2/2): 混合行列、モデルの精度、再現率、適合率

製品の実際の良否: ● 不良品 ● 良品

概念の説明: 混合行列とは

2種類の分類問題における、モデルが判断した分類結果のまとめ

形式は2×2の行列となり、モデルの性能を測る指標として使用される

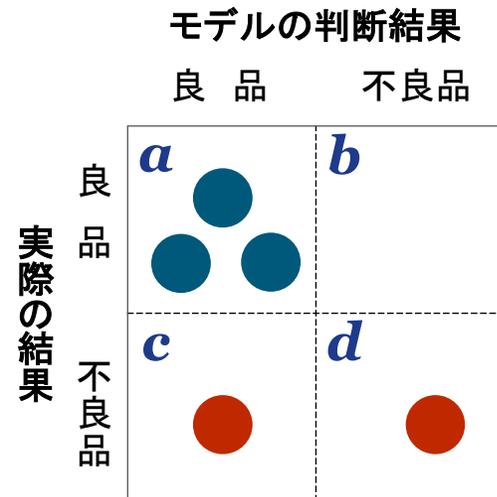
具体例

対象製品 モデルの判断結果

- 良品
- 良品
- 良品
- 良品
- 不良品



混合行列による結果評価



モデルの精度(正解率)はモデルがどの程度正しく良品・不良品を判断したかを評価する指標
計算式:
 $(a+d)/(a+b+c+d)$

再現率は実際に不良品のうち、モデルが正しく不良品と判断した製品の割合(検知漏れの指標)
計算式: $d/(c+d)$

適合率は不良品と判断した製品のうち、実際に不良品である割合
計算式: $d/(b+d)$

不良判断の閾値を変えると混合行列が変わり、評価指標となるモデルの精度・再現率・適合率も変化

中でも、不良品を良品と誤判断することを避けるため、再現率が重要な指標

B2

【モデル構築】データの学習とモデルの精度検証、実装準備: 参考) 外観検査AI構築に使用可能なGUIツール例

2021年3月時点

- ✓ 日本語UI・サイトがある場合
- ✓ 日本語UIはないがサイトがある場合
- 本ガイドブックでの説明に使用

提供企業	ツール名称	日本語対応	
		ツールを日本語で使用可能	日本語電話サポートあり
Google	Google Cloud Vision AI	✓	✓
日本アイ・ビー・エム株式会社	IBM Visual Insights	✓	✓

クラウドサービスの内容には変更が生じる場合があるため、最新の情報は各ウェブサイトをご確認ください

B2 【モデル構築】データの学習とモデルの精度検証、実装準備

データ準備(ラベル付け): 学習させる画像データへ良品・不良品のラベルを付与

作業手順

詳細

Google Cloud Vision AIの例

ラベルを作成

良品と不良品2種類のラベルを作成

新規ラベルを追加

ラベル名: ng_product

CANCEL 完了

「新規ラベルを追加」を押し、良品・不良品のラベル名¹を作成してから「完了」ボタンを押して保存

画像データにラベルを付与

アップロードした全ての画像に対し、1枚1枚作成したラベルを付与

ラベルの割り当て

ラベルをフィルタ

1個選択されています

ラベルの割り当て

gd_product

ng_product

ラベルなし

保存 キャンセル

画像を選択し(複数選択可)、正しいフラグを付けて保存

1. Google Cloud Vision AIの場合、ラベル名はアルファベットのみ

B2 【モデル構築】データの学習とモデルの精度検証、実装準備

モデル構築・最適化(モデル確定): 最適なモデルと閾値を特定

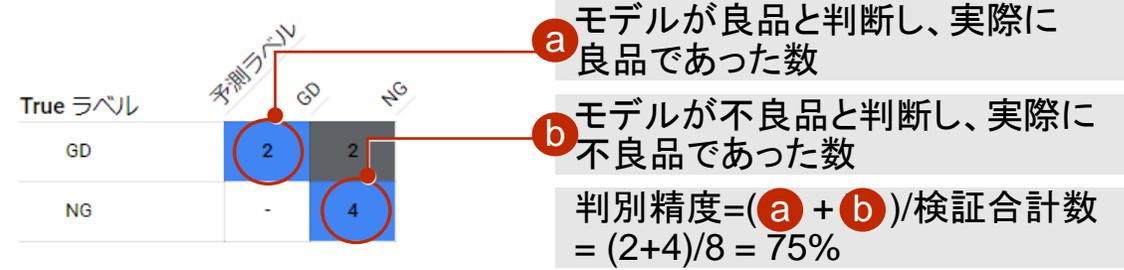
作業手順

詳細

Google Cloud Vision AIの例

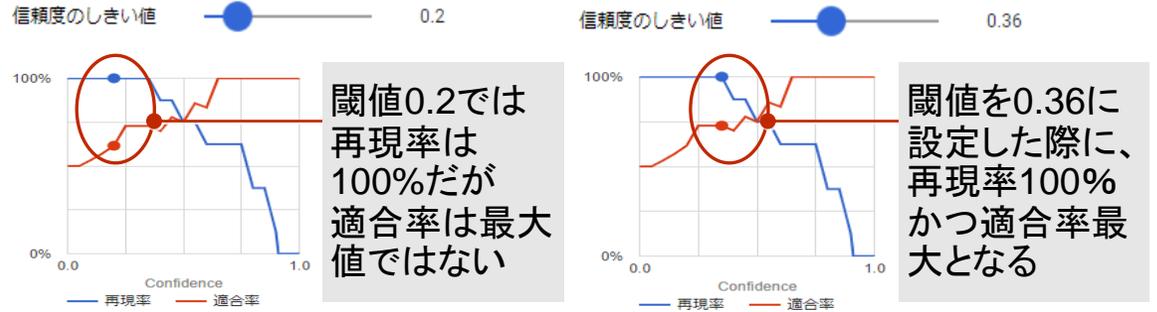
構築した複数のモデルから最適モデルを選択

不良判定の閾値¹が一定の際に(例えば閾値0.5)、検証用データに対し予測精度の一番高いモデルを最適モデルとして選択



モデルの不良判定の閾値を初期的に特定

最適モデルの閾値を調整しながら、再現率²が100%かつ適合率³が最大値となる閾値を特定 (AIが良品と判断した中に不良品が混じることを避けるため、再現率100%から始める)



実製品を用いてモデルの精度を検証しながら、閾値を調整(P.54参照)

上記閾値を初期値として、AIによる検査と人による検査を実施。結果を基に最適な閾値を特定

1. モデルが判定する「不良品の確率」に対し、何%以上のものを不良品として判別するか。例: 閾値0.36の場合、「不良品の確率36%以上」の場合に「不良」と判断
 2. 本当に不良品である製品の内、何%を不良品と判断できたか
 3. 不良品と判断した製品の内、何%が実際に不良品であったか

B2 【モデル構築】データの学習とモデルの精度検証、実装準備

モデル導入準備(1/3): 構築したモデルと各機材を接続するためのコードを開発

作業手順	詳細	例
<h3>カメラと接続</h3>	<p>近年のウェブカメラの場合、標準化されたコードを用いて接続¹</p> <p>一部の産業カメラ等、標準コードが適応できない場合はカメラメーカーの技術サポートに問い合わせ (必要なコードを入手可能な場合あり)</p>	<h3>Pythonによる標準コード</h3> <pre> import numpy as np import cv2 import os from keras.models import load_model cap = cv2.VideoCapture(0) #cap.set(3,500) #cap.set(4,500) cap.set(15, -7) # input paramter timelag_punch = 7 model_path = "C:/Users/Desktop/model-1.tflite" defect_threshold = 0.7 # initiate parameters check_cnt = 0 sense_ = [True] count_ = -1 pred_list = [0] msg_count = str(0) + " passed" pred_update_save = 0 while(1): # read frame, count # of frame check_cnt = 1 + check_cnt ret, frame = cap.read() img_cap = cv2.cvtColor(frame, cv2.IMREAD_COLOR) img_ = prepare(img_cap) # initial pred_update which used to find max predict pred_update = 0 </pre> <p>接続するカメラのIDを入力 例における接続対象カメラのIDは0</p> <p>モデルの保存場所(=パス)を入力 例におけるモデルのパスは C:/Users/Desktop/model-1.tflite</p>
<h3>不良除去装置等他装置と接続</h3>	<p>不良除去装置との接続には主に3つの作業が必要</p> <ul style="list-style-type: none"> モデルから不良除去装置に送る信号の設計² パソコンからの信号を電流のオン・オフに変換する装置の準備(例: USB型装置) 不良除去装置の用意(例: DC型エアガン) 	

1. 開発言語にはPython, C++, JS等選択肢があるものの、ウェブ検索により接続のサンプルコードの入手は可能
 2. 例: 3つの信号を設計。製品毎の良品・不良品の判断結果「0/1」、製品が不良除去装置に到着するまでの時間「X秒」、電流の制御「0/1」

B2

【モデル構築】データの学習とモデルの精度検証、実装準備

モデル導入準備(2/3): モデルの精度と検査時間を確認し、導入の可否を決定

製品の実際の良否 ● 不良品 ● 良品

出来上がったモデルを使用し、実際の導入と同じ条件で製品を検品し、精度と検査時間を確認

精度

- 同一の製品に対し、人間の目視検査とAIによる検査を平行して実施
- 不良品率を考慮し、不良品が発生し得る個数分の製品を用意(次頁参照)

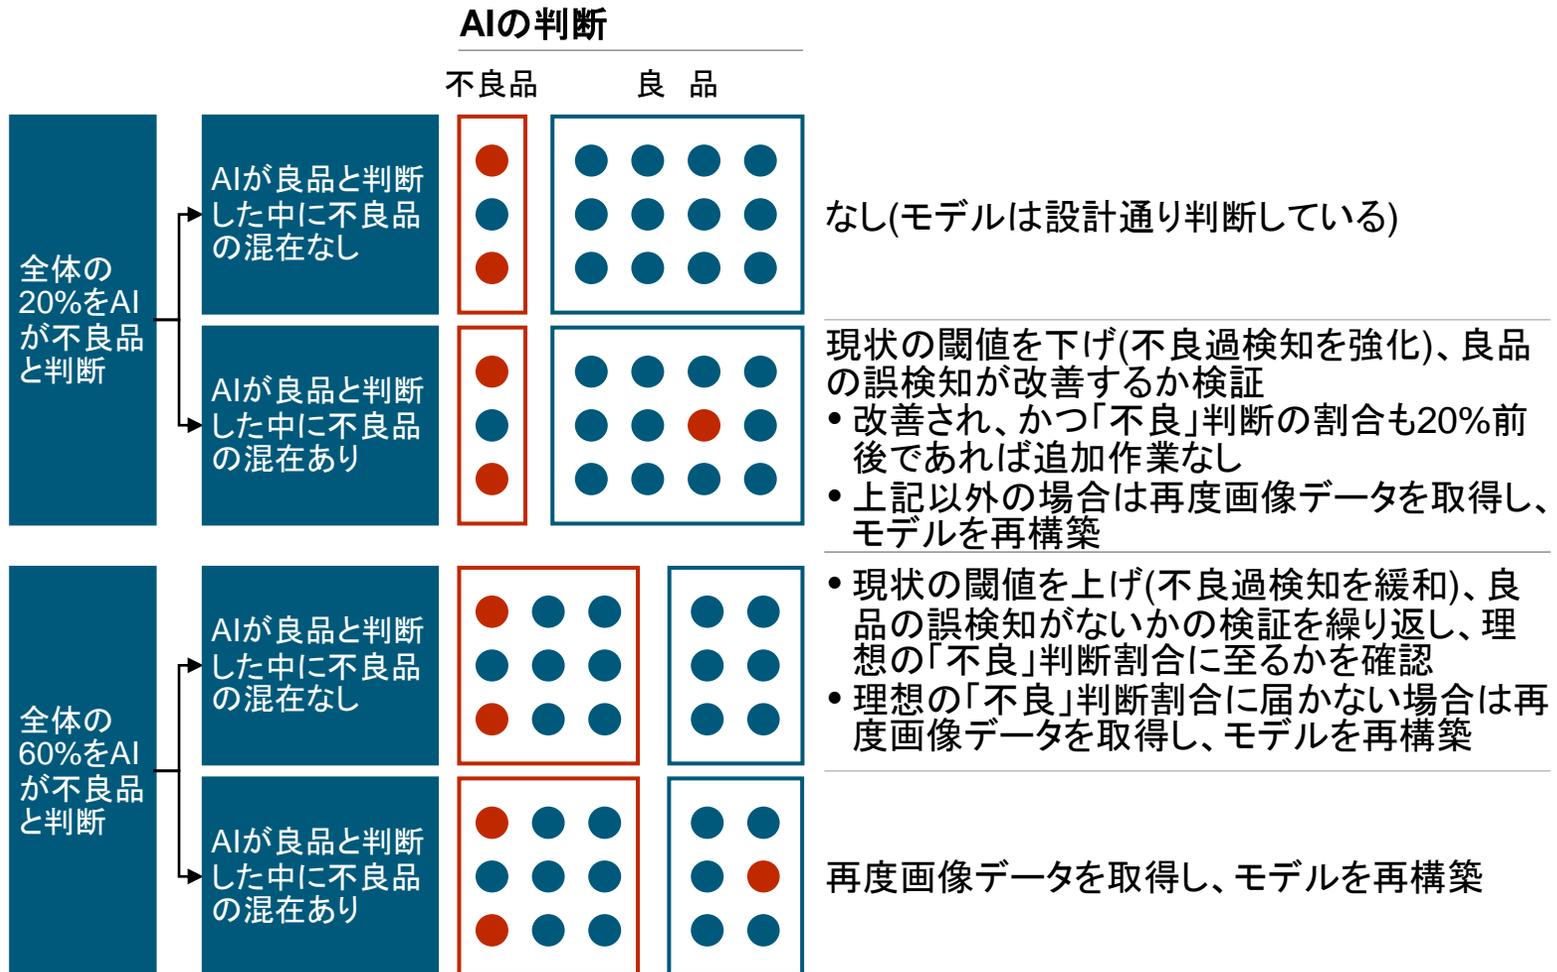
検査時間

- AIを使用した検品を実施し、導入前と比較してどの程度検品時間が削減したか検証

精度に関するモデルの判断結果例

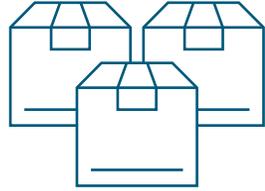
AIによる「良品」判断に不良品の混在なし、「不良」判断を全体の20%程度を目指す場合

必要な作業



【モデル構築】データの学習とモデルの精度検証、実装準備

B2 モデル導入準備(3/3): モデルの精度確認を行う際の検査製品数の考え方



生産数が多い場合

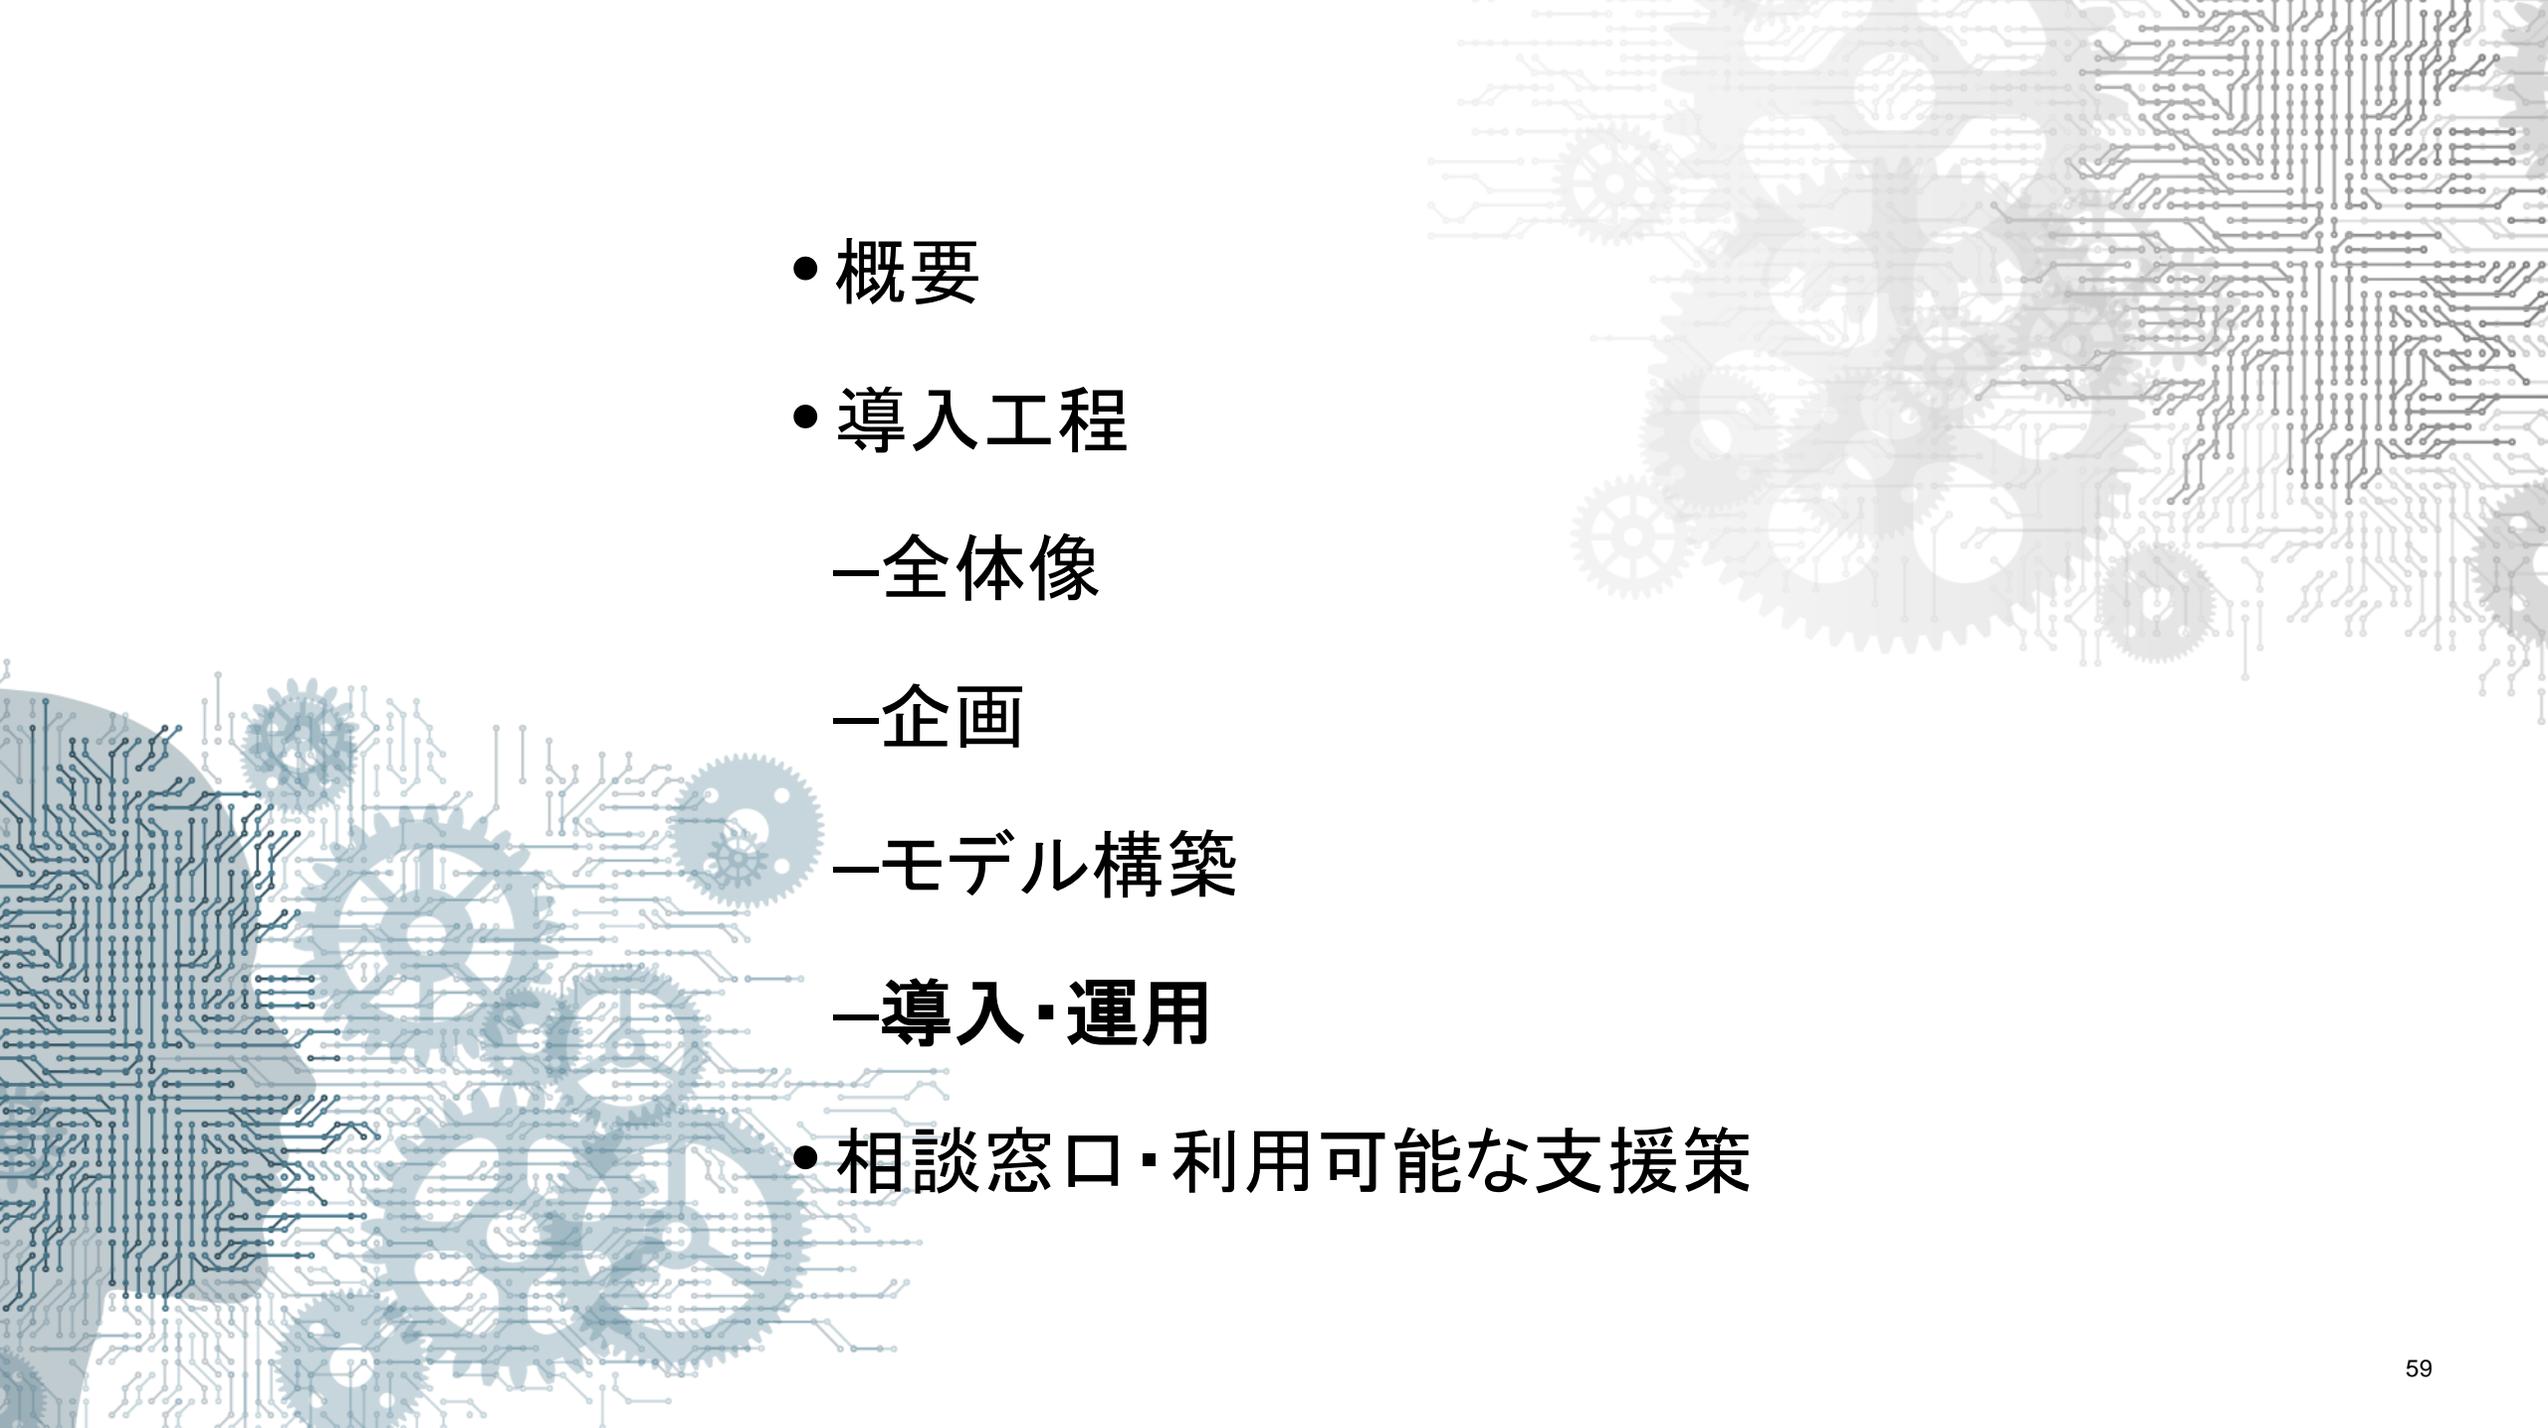
1万個製品を用意。不良品が計算上20~30個入る個数分(ただしそれが1,000個を下回る場合は1,000個)を任意に抜き出し検査
 例: 不良品率2.5%なら
 1,000~1,200個



生産数が少ない場合

不良品が計算上20~30個入る個数分を検査(不良品率に応じて難しければ5~10個入る個数分)
 例: 不良品率5%なら400~600個
 (最低100~200個)

左記はあくまで目安となる考え方。実際には、製品特性・検査条件(例: 生産数、不良品率、仕入れ先の要望)に応じて、一部の検査を人に代えて実施しても問題ないと判断できる程度まで精度を確認

- 
- 概要
 - 導入工程
 - 全体像
 - 企画
 - モデル構築
 - 導入・運用
 - 相談窓口・利用可能な支援策

企画から導入・運用までの導入工程全体像

■ 本章で説明する工程



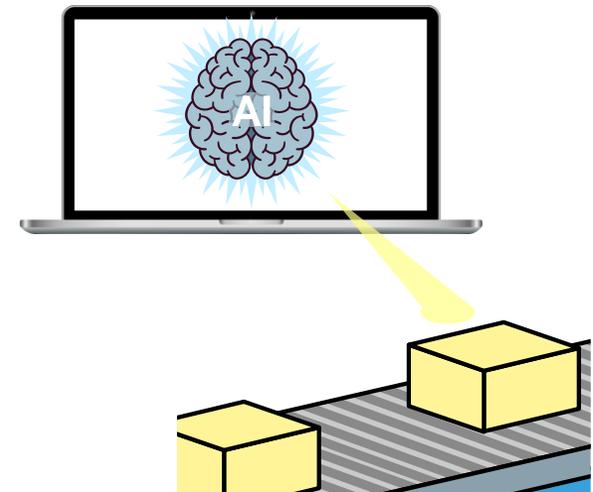
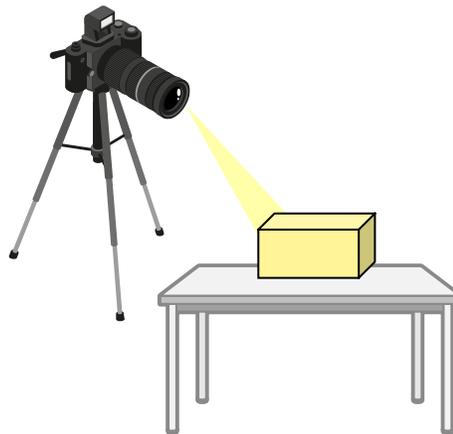
- 改善点の把握
- 対象製品の決定
- 導入後の検査工程再設計

- 機材の見積り・手配の開始

- 用意する画像データの定義
- 撮影機材の選定
- 撮影方法の特定

- モデル構築の基本理解
- データの学習とモデルの精度検証、実装準備

- 検査現場へのモデル・機材の設置
- 新たな検査方法の浸透
- 定期的なモデルの再学習・再構築



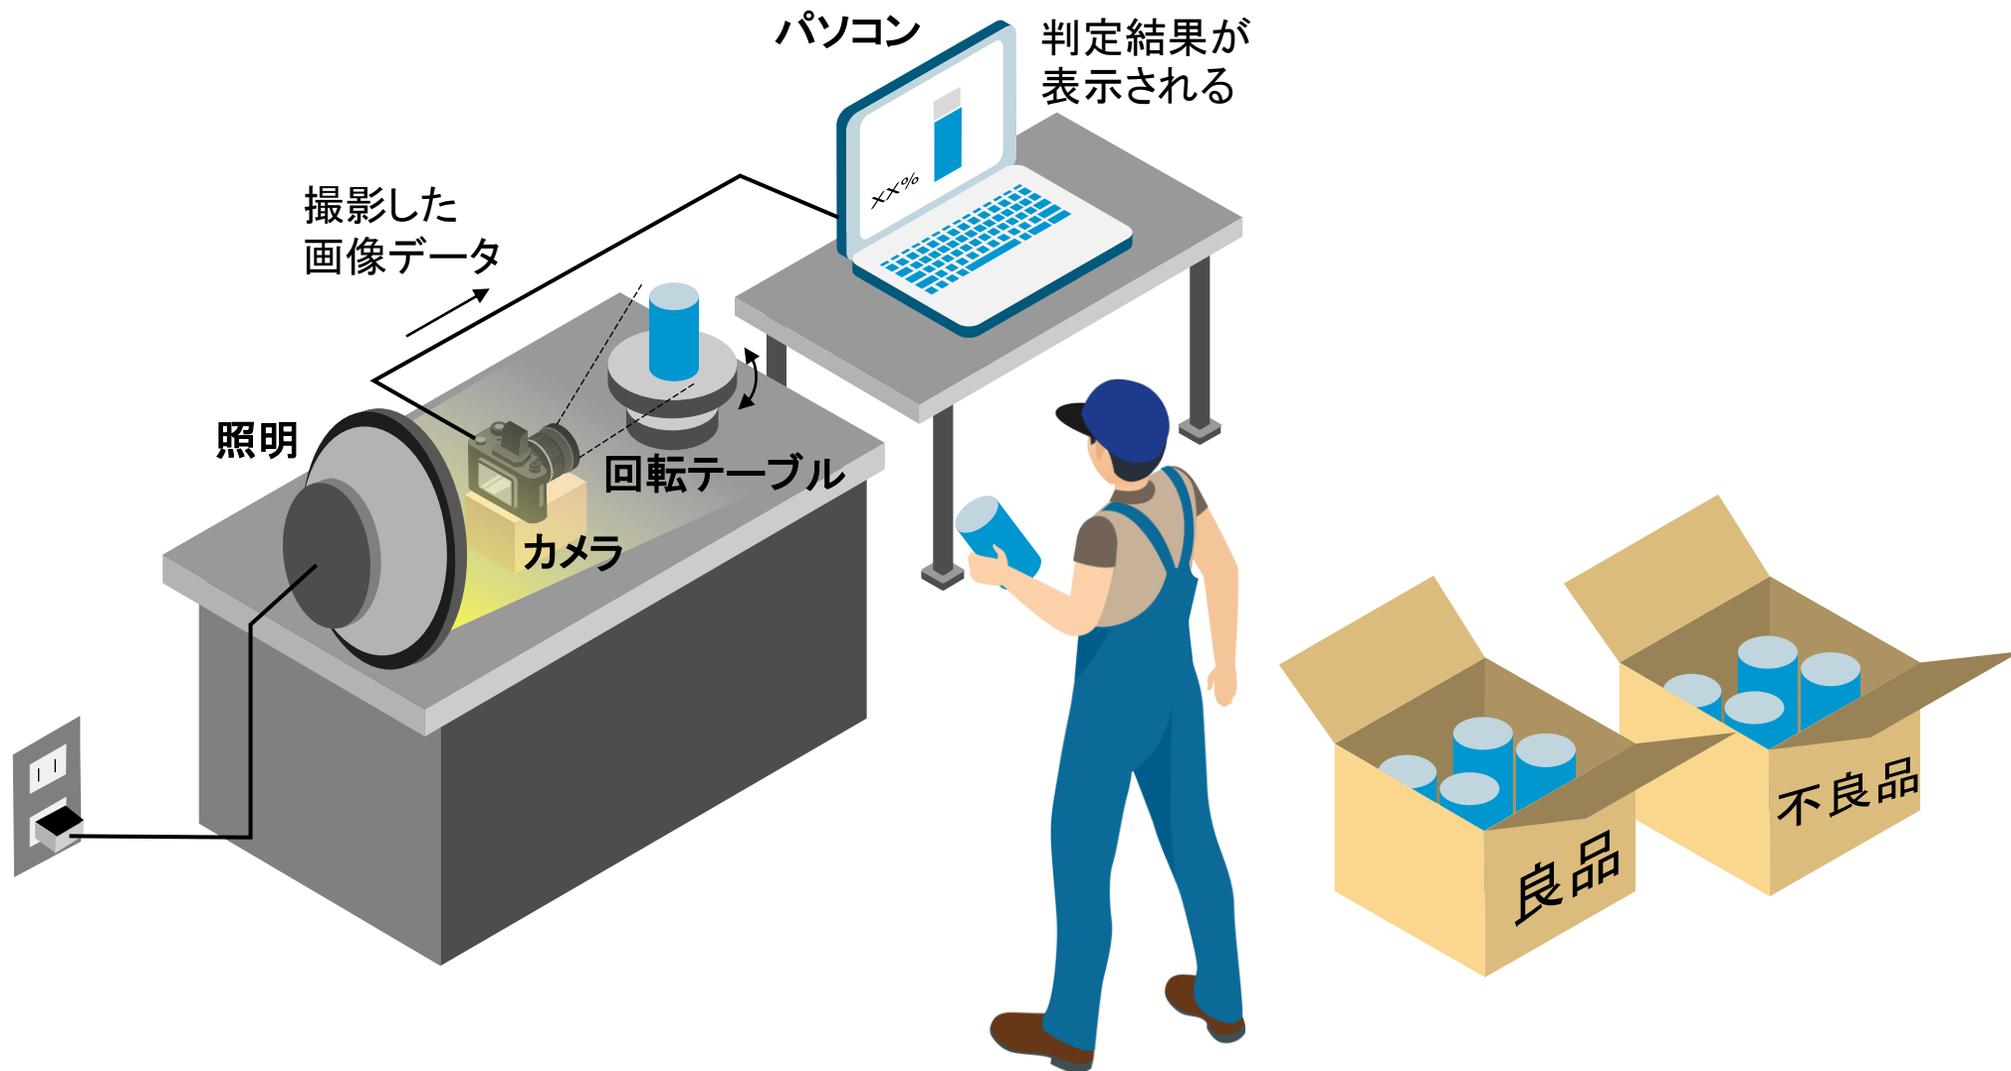
C 【導入・運用】検査現場へのモデル・機材の設置(1/3): よくある不具合例と考えられる原因・対応策

よくある不具合例	考えられる原因	対応策 ¹	
ハードウェア系	<ul style="list-style-type: none"> 装置は動いているが、カメラが映らない 	<ul style="list-style-type: none"> カメラとパソコンの接続不良、またはカメラの不具合 	<ul style="list-style-type: none"> カメラとパソコンの接続を確認。カメラの不具合の場合はカメラメーカーに相談
	<ul style="list-style-type: none"> パソコン画面が映らない(電源が入らない) 	<ul style="list-style-type: none"> パソコンあるいはOSの不具合 	<ul style="list-style-type: none"> パソコンを再起動し、問題が解決できない場合はパソコンメーカーに相談
	<ul style="list-style-type: none"> パソコン・カメラは正常に稼働し、パソコン画面上の不良判定も正常だが、不良品を弾く装置が動かない 	<ul style="list-style-type: none"> 不良を弾く装置の接続不良、あるいは弾く装置の不具合 	<ul style="list-style-type: none"> 不良を弾く装置の接続を確認。改善しない場合は弾く装置のメーカーに相談
ソフトウェア系	<ul style="list-style-type: none"> パソコンは動いているが、装置全体が止まり、パソコン画面にエラーメッセージが表示される 	<ul style="list-style-type: none"> 装置全般を制御するプログラムのバグ 	<ul style="list-style-type: none"> AI人材やAIベンダーに相談してバグを検出
	<ul style="list-style-type: none"> 装置全体は動いているが、不良判定の比率がおかしい(例: 全製品不良に判定) 	<ul style="list-style-type: none"> 間違ったAIモデルの参照 AIが動く環境の変化(例: 設置場所の移動により光の当たり方が変化) 	<ul style="list-style-type: none"> AIモデルの参照場所を再度確認 環境(例: 照明、ベルトコンベア)が変わった場合にはAIモデルの再構築が必要
	<ul style="list-style-type: none"> GUIの画面にアクセス不可、あるいは画面の操作に支障がでる 	<ul style="list-style-type: none"> GUIアクセスに最適なブラウザが使われていない ブラウザのバージョンが古い 	<ul style="list-style-type: none"> GUIの推奨環境、もしくは対応のブラウザに切り替え ブラウザのバージョン更新

1. 原因が特定できない場合は、AIベンダー等への相談も検討

C 【導入・運用】検査現場へのモデル・機材の設置(2/3) 設置方法具体例【機械自動化度が低い事例】

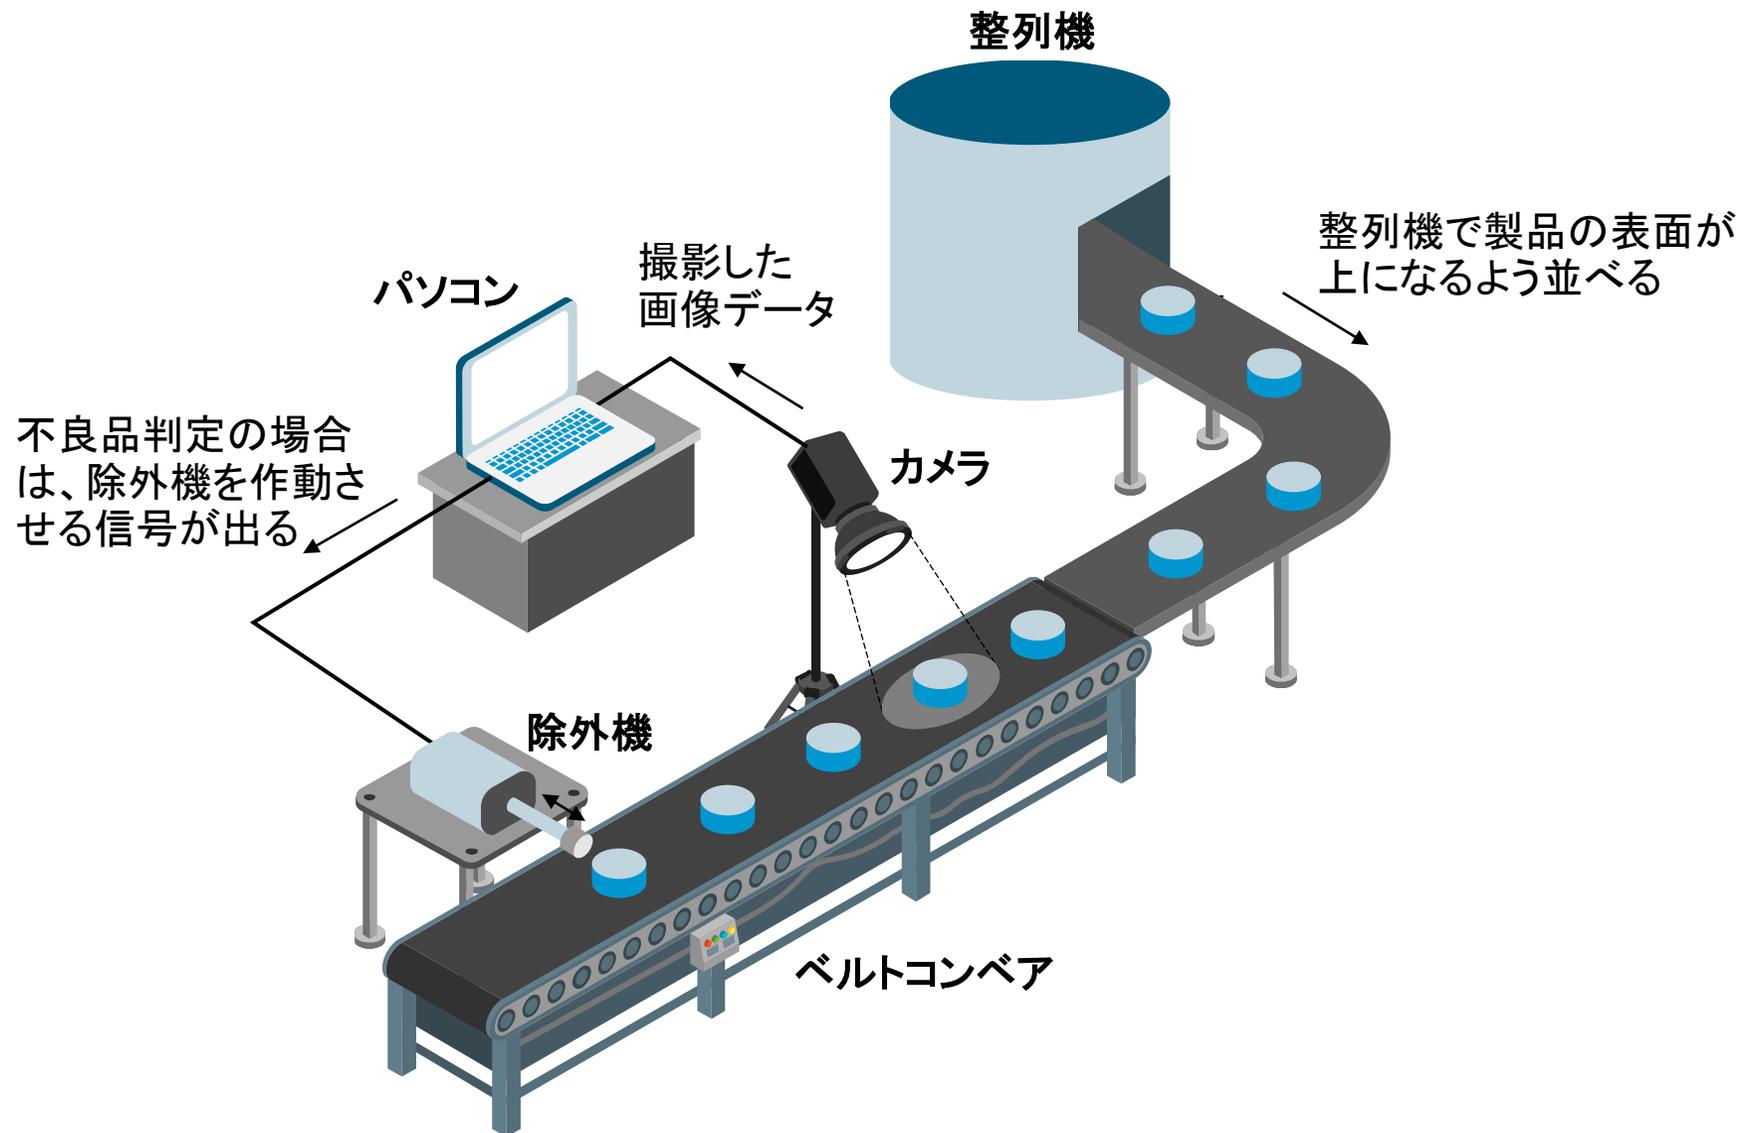
- あ1 製品の配置を手で実施
- あ2 製品の配置を機械で実施



あ1 製品の配置を手で実施

あ2 製品の配置を機械で実施

C 【導入・運用】検査現場へのモデル・機材の設置(3/3) 設置方法具体例【機械自動化度が高い事例】



C 【導入・運用】新たな検査方法の浸透: AI活用効果の最大化のため、使用上の注意点の書き出し等を通じて新たな検査方法を現場へ浸透させる

効果を最大化するには、AIを活用した新たな検査方法を現場へ浸透させることが重要

どれだけ精度の良いモデルを構築しても、使用方法が誤っていたり属人的だったりするとAIの判断が不正確に... **常に同じ・正しい方法でAIが使用されるよう、新しい検査方法を浸透・徹底させることが必要**

よくある注意点例

- 窓からの自然光を遮断せずに検査を行い、写真の明度が変わってしまった
- 製品を置く位置が人によって微妙に異なるため、写真に写る製品の大きさ・ピントがずれてしまった

現場へ浸透させる方法例



注意書きの設置

検査現場に特に気を付けるべき注意点を貼り出し、検査員が毎回参照できるようにする



製品設置の装置

検査員によって撮影環境が変わらないよう、製品を置く場所を固定できるように撮影台に細工



作業手順書

検査工程を分かりやすく記した手順書を作成



研修(OJT)

装置を実際に使いながら新しい検査工程を説明

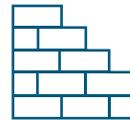
また、**導入工程初期から検査員を巻き込む**ことで、AIへの理解や検査方法の浸透を効率的に図ることも可能

C 【導入・運用】定期的なモデルの再学習・再構築(1/3): 運用において、モデルの更新(再学習・再構築)や使用停止等の意思決定が必要となる



モデルの再学習

既に作成したモデルの学習用画像データに、新たな画像を追加してモデルを再学習



モデルの再構築

学習用画像データを全て刷新し、新たな写真を用いて再度モデルを構築



AIの使用を停止

対象製品の生産量が減少した場合等に、AIを活用した検品の取りやめ

C 【導入・運用】定期的なモデルの再学習・再構築(2/3): 製品や不良品基準等の変更に応じて、AIモデルの再学習や再構築を行う

再学習・再構築の考え方

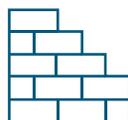
- 対象製品や、不良品の基準・検品環境に変化が生じた場合には、精度低下の恐れがあるため、モデルの再学習・再構築を検討
- 上記のような明らかな変化がない場合にも、定期的にAIの精度を検証し、著しい変化があった場合にも原因を特定した上でモデルの再学習・再構築を検討(次頁参照)



モデルの再学習 から検討

再学習・再構築を検討すべき状況の例

- 製品の製造条件の変更
 - 製造工程が一部変更
 - 製品製造の工程の外注先に新たな会社が追加
- 不良品基準の部分的な変更
 - 新しい不良品の類型が発生
 - 納入先から新たな不良の類型が通知



モデルの再構築 から検討

- 不良品基準の大幅な変更
- 製品の仕様の変更
- 検査・撮影環境の変化
 - 外観検査AI設置場所の変更
 - カメラや照明の種類・位置の変更
 - 撮影背景の変更

C 【導入・運用】定期的なモデルの再学習・再構築(3/3): 製品や不良品基準等の変更がない場合にも定期的に精度を検証

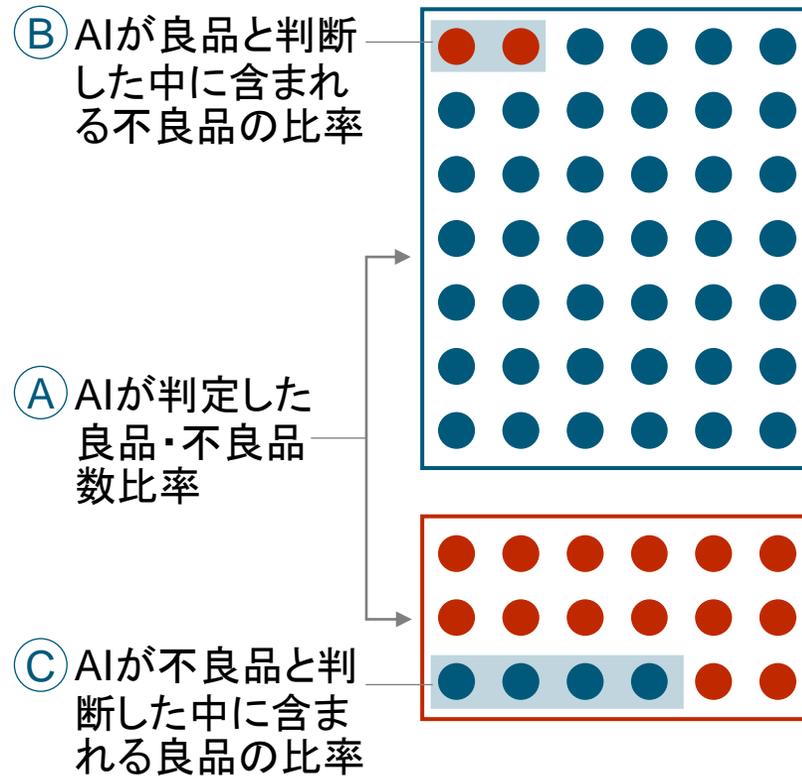
再学習・再構築の考え方

- 対象製品や、不良品の基準・検品環境に変化が生じた場合には、精度低下の恐れがあるため、モデルの再学習・再構築を検討(前頁参照)

- 上記のような明らかな変化がない場合にも、定期的にAIの精度を検証し、著しい変化があった場合にも原因を特定した上でモデルの再学習・再構築を検討

□ AIが良品と判断 □ AIが不良品と判断 製品の実際の良否: ● 良品 ● 不良品

精度検証方法例



毎回の検査で、① および③を確認

月に1回程度、一定数¹の製品を目視とAIで重複検査し②の数値を確認

毎回の検査の度に、一定数の製品を目視とAIで重複検査し、① ② ③ の数値を確認²

小
↑
検証負担の大きさ
↓
大

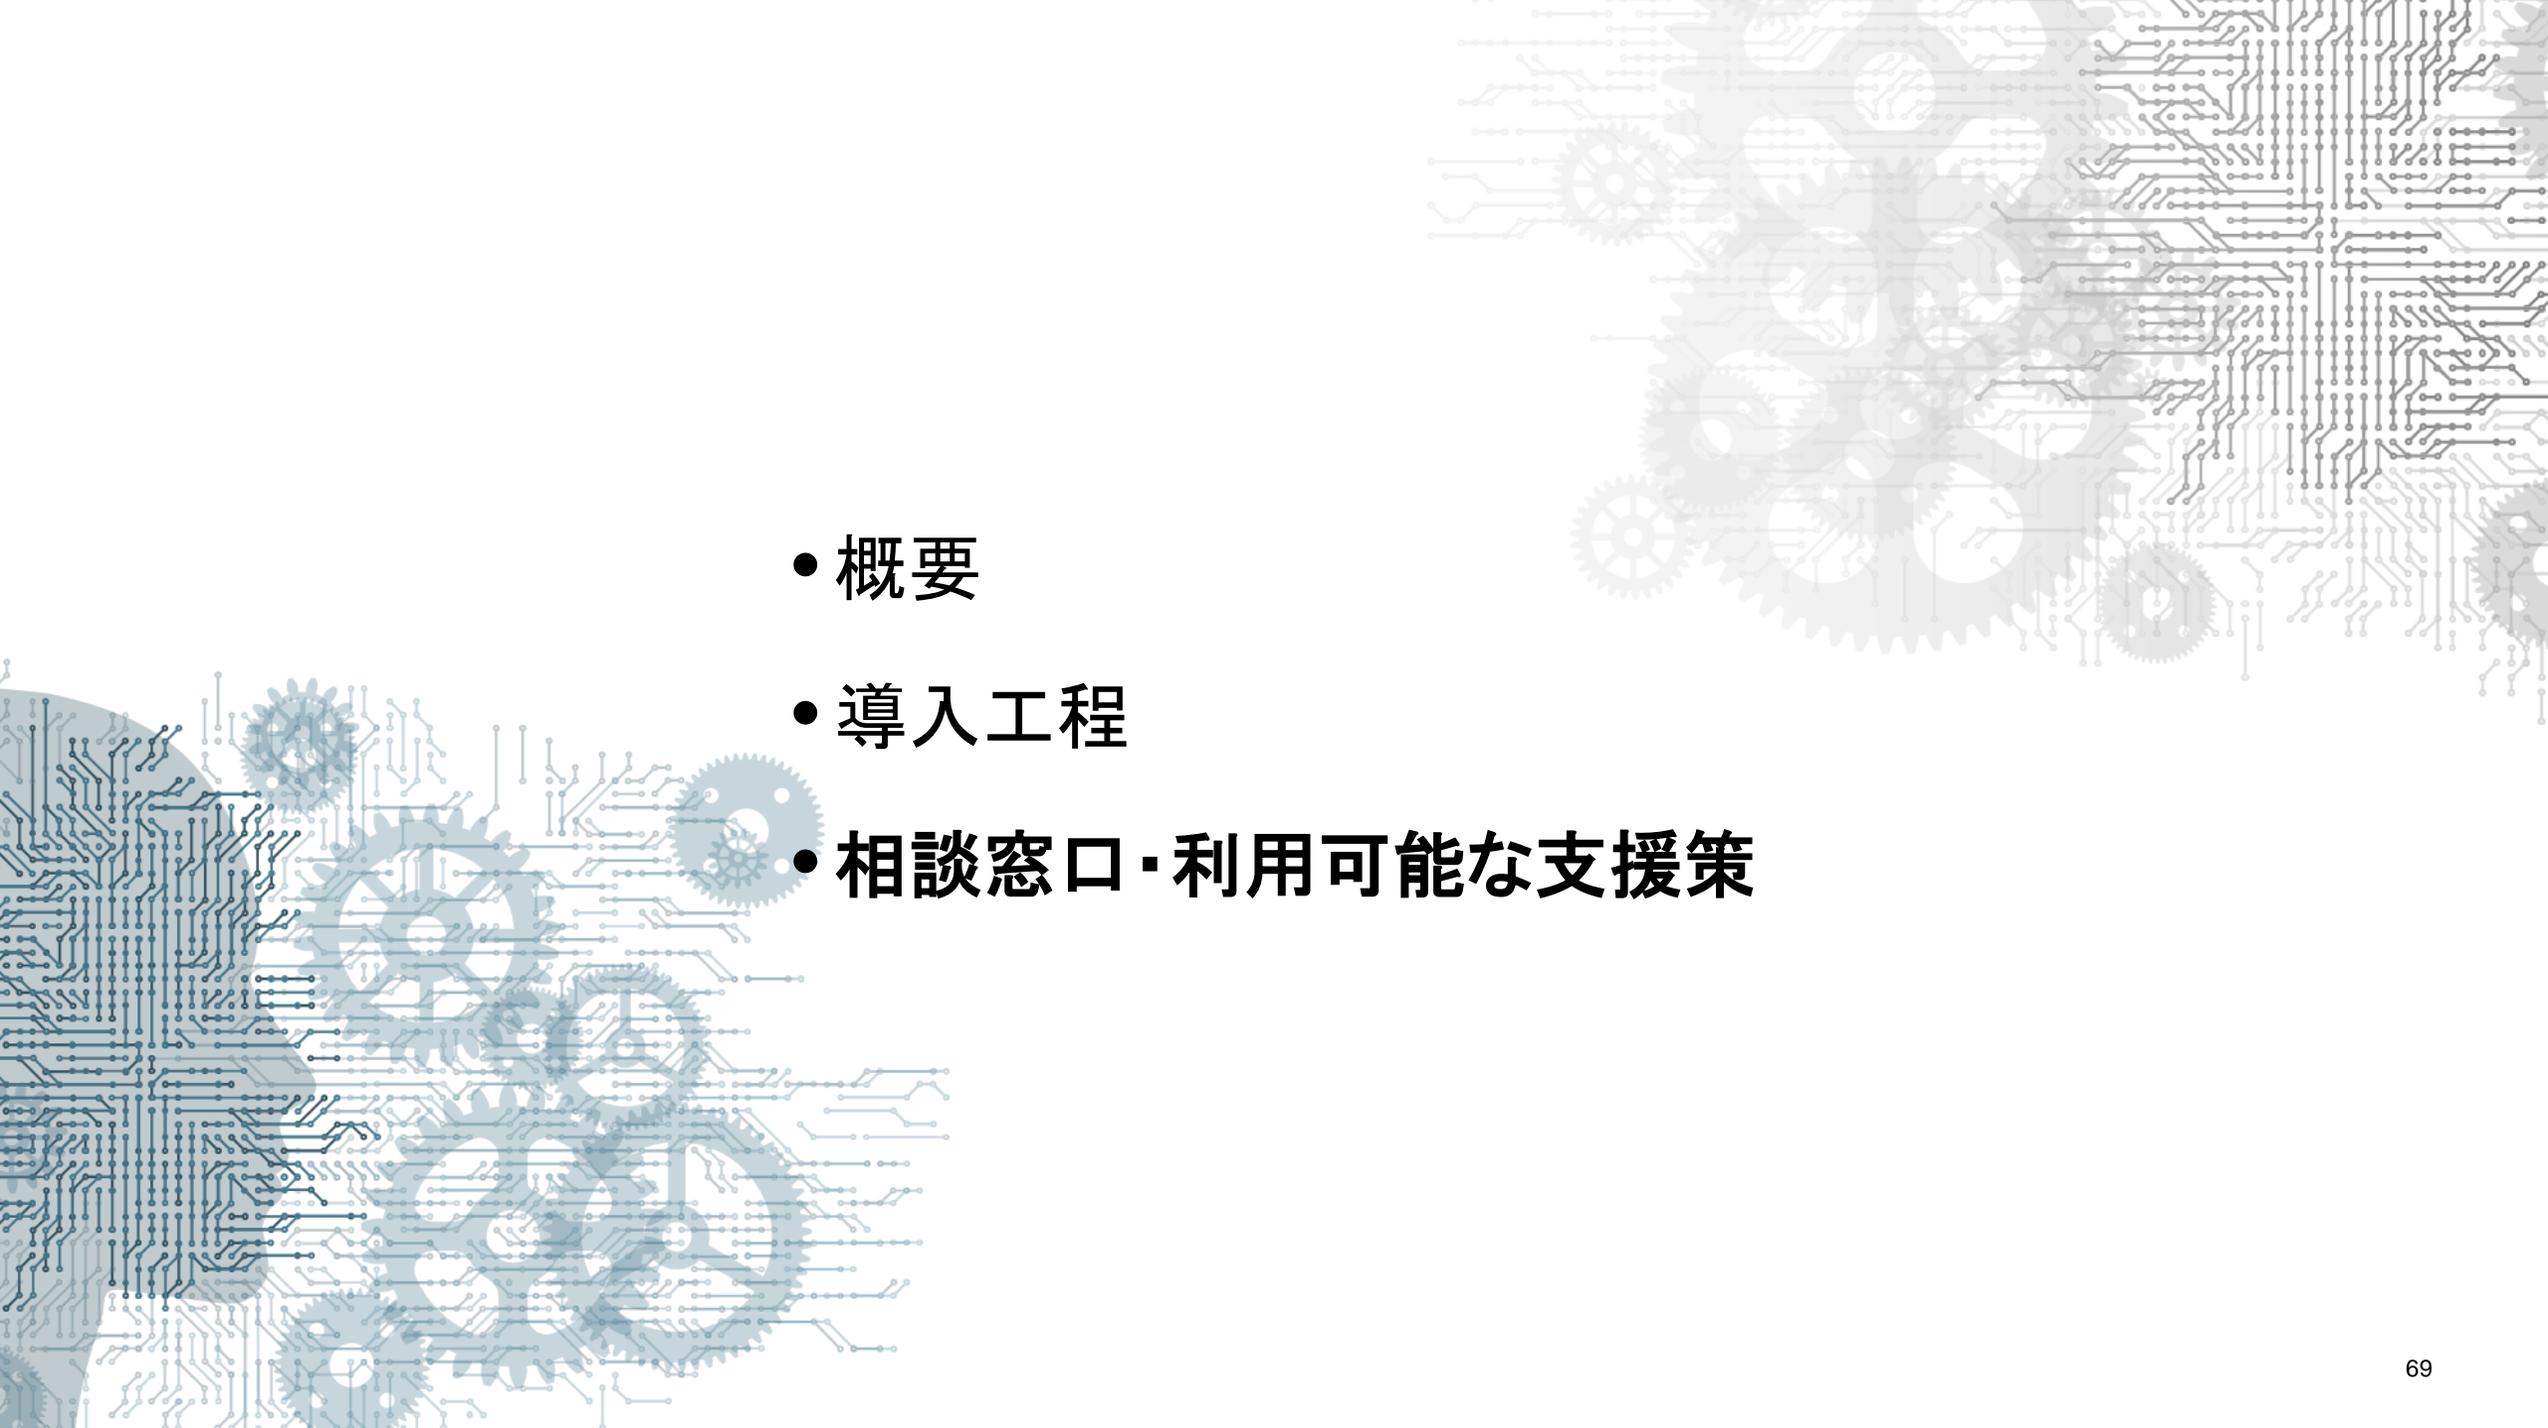
1. 不良品率を鑑み、計算上不良品が数個発生する個数分の検査をすることが望ましい
2. 元々人が二重・三重の検査を行っていた工程の一部をAIに代替する場合などに実施可能

③【導入・運用】 他製品への外観検査AIの展開

本導入工程を経て獲得した知見は、
他製品への外観検査AI導入に生かす
ことが可能

新たな製品への展開の際には、
AI導入による効果が大きい製品という
観点から、対象製品を選択(P.23,24参照)

個々の製品・生産ロットを追跡できる方法があれば、
不良が発見された製品・ロットから速やかに不良
発生の原因を特定し改善に繋げる等、外観検査
AIの活用を更に発展させていくことも可能

- 
- 概要
 - 導入工程
 - 相談窓口・利用可能な支援策

AI導入の際に活用できる国・地域の窓口

本ガイドブック内容に関する
お問い合わせ

経済産業省商務情報政策局 情報技術利用促進課
• 電話番号: 03-3501-2646

AI導入・活用の支援に関するお問い合わせ

AI導入・活用の現場で実際に支援

中小企業デジタル化応援隊事業

登録されたIT専門家が、中小企業の要望に基づき、AIも含めたIT導入を現場で実際に支援します(一部費用負担あり)。詳細は、事業事務局特設ウェブサイトをご覧ください

- 事務局特設ウェブサイトURL: <https://digitalization-support.jp>
- コールセンター: 050-2000-7227 (平日9:00~17:00)

AI導入・活用を行う際の支援策等をご紹介

経済産業局

中小企業がAI導入を行う際の支援策等の相談に応じます(他の窓口をご紹介する場合もあり)

名称	担当課	電話番号	ウェブサイト
北海道経済産業局	製造・情報産業課	011-700-2253	なし
東北経済産業局	情報政策室	022-221-4895	https://www.tohoku.meti.go.jp/s_joho/index_joho.html
関東経済産業局	デジタル経済課	048-600-0284	https://www.kanto.meti.go.jp/seisaku/iot_robot/index.html
中部経済産業局	情報政策室	052-951-0570	なし
近畿経済産業局	次世代産業・情報政策課	06-6966-6008	https://www.kansai.meti.go.jp/2-7it/ai/ai_top.html
中国経済産業局	製造・情報産業課	082-224-5630	なし
四国経済産業局	製造産業・情報政策課	087-811-8520	なし
九州経済産業局	情報政策課	092-482-5440	https://www.kyushu.meti.go.jp/seisaku/jyoho/kyushu-iot.html
沖縄総合事務局	経済産業部地域経済課	098-866-1730	http://www.ogb.go.jp/keisan

AI導入の際に活用できる補助金制度の例

2020年12月時点

制度名	ものづくり・商業・サービス生産性向上促進補助金	戦略的基盤技術高度化支援事業(サポイン事業)	商業・サービス競争力強化連携支援事業(新連携支援事業)	
概要	中小企業者等が行う「革新的な製品・サービス開発」または「生産プロセス・サービス提供方法の改善」に必要な設備・システム投資等を支援	中小企業者等が大学・公設試等の研究機関等と連携して行う、製品化に繋がる可能性の高い研究開発、試作品開発等および販路開拓への取り組みを支援	中小企業者が産学官で連携し、また異業種分野の事業者との連携を通じて行う新しいサービスモデルの開発等のうち、地域経済を支えるサービス産業の競争力強化に資すると認められる取り組みを支援	
補助内容	補助上限	1,000万円	単年度:4,500万円 3年間合計:9,750万円	初年度:3,000万円 2年度:初年度の交付決定額と同額
	補助率	中小企業:1/2以内、 小規模事業者:2/3以内	中小企業・小規模事業者:2/3以内 大学・公設試等:定額	補助対象経費の1/2以内 (AI・IoT等の先端技術活用の場合 は2/3以内)
	補助対象経費	機械装置・システム構築費、技術導入費、専門家経費、クラウドサービス利用費、外注費、知的財産権等関連経費等	設備備品費、人件費、技術導入費、通訳・翻訳費、知的財産権関連経費、マーケティング調査費、委託費等	研究員費、謝金、知的財産権関連費、マーケティング調査費、機械装置等費、委託費等

詳細や申請方法は各制度のホームページよりご確認下さい

ご協力企業・団体一覧(五十音順)

2021年3月時点暫定版

アベル株式会社

一文字厨器株式会社

一般社団法人 日本ディープ
ラーニング協会

上田製袋株式会社

栄商金属株式会社

大阪商工会議所

大阪府IoT推進Lab

株式会社O2

嘉穂無線ホールディングス
株式会社(株式会社グッデイ)

Google

株式会社グリッド

小橋工業株式会社

株式会社SIGNATE

墨田加工株式会社

株式会社中央電機計器
製作所

テクノスデータサイエンス・
エンジニアリング株式会社

東京商工会議所

株式会社戸畑ターレット

日本商工会議所

武州工業株式会社

有限会社ミツミ製作所

八尾市産業政策課

株式会社山本金属製作所

株式会社友電舎

株式会社ヨシズミプレス

株式会社Lightblue
Technology

株式会社リバナス

