

株式会社 リッジアイ

ディープラーニングは実用段階に。
PoCを乗り越えるためのノウハウ

2019年9月25日



Ridge-i

- 会社紹介
- AIの注目度と日本の現状
- 私たちのアプローチ
- 弊社事例紹介
- AI導入の課題
- まとめ
- 質疑応答

会社概要

Ridge-i (リッジアイ) 概要



ミッション

最高峰の先端技術を活用し、ビジネスの最高地点を
クライアントと共に目指す

事業領域

ビジネスニーズに最適化した
AI技術を提供

① AIコンサルティング・ ソリューション開発

機械学習・画像系ディープラーニング
が中心

② 共同プロダクト開発

AI×αによる強みの相互補完

③ 新規事業創出支援

大企業とのオープンイノベーション

会社概要

オフィス

- 千代田区大手町
1-6-1

従業員数

- 29名 + α
機械学習エンジニア、
コンサルタント

※9/25 本日オフィス引っ越し。
3-4倍に拡張

パートナーシップ



RICOH

global
brain



※2019年4月 総額7.5億円の第三者出資



柳原 尚史 (やなぎはら たかし)

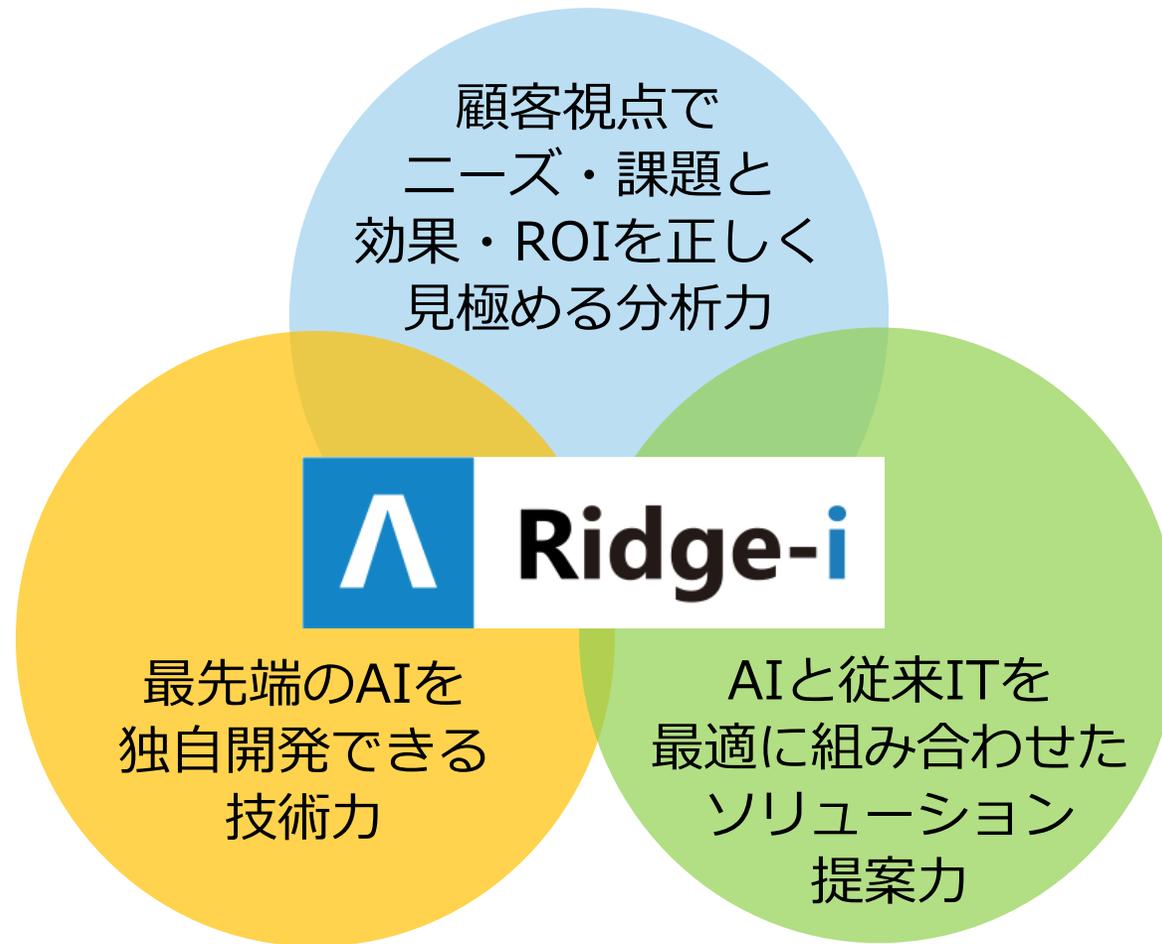
ブラックロックなど世界最大の大手金融機関にて、取引所高速接続、高頻度取引、リスク分析、アルゴリズム取引の設計・開発などに10年従事。

2016年にディープラーニングを中心としたAI技術の可能性を、より広い業界・社会に適用するためにRidge-iを創立、現在に至る

- 小4からプログラマー。
- 早稲田大学在学中にプレイステーションゲーム開発
- 内閣府、総務省、経産省主体の複数の衛星事業に関する委員
- 3児のパパで、趣味はトレイルランニング
 - 富士山1日3往復
 - UTMB (モンブラン 一周170Km) 45時間寝ずに走破
 - 9/14 トルデジアン (330km 累積標高30000m) を147時間で完走



豊富なAI導入実績を支える 3つの強み



ビジネスニーズに最適なAIソリューションを提供します



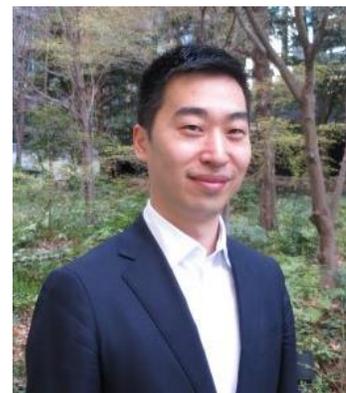
社外取締役
田丸 健三郎

日本マイクロソフト
業務執行役員
National Technology
Officer



取締役副社長
小松 平佳

早稲田大学理工学卒
SUBARU,
ボストンコンサル
ティングを経て参画



執行役員
杉山 一成

東京工業大学大学院
理工学研究科卒
ボストンコンサル
ティングを経て参画



CRO (非常勤)
牛久 祥孝

東京大学 大学院
情報理工学系研究科
博士課程修了
画像認識技術コンテスト
「ILSVRC 2012」で2位

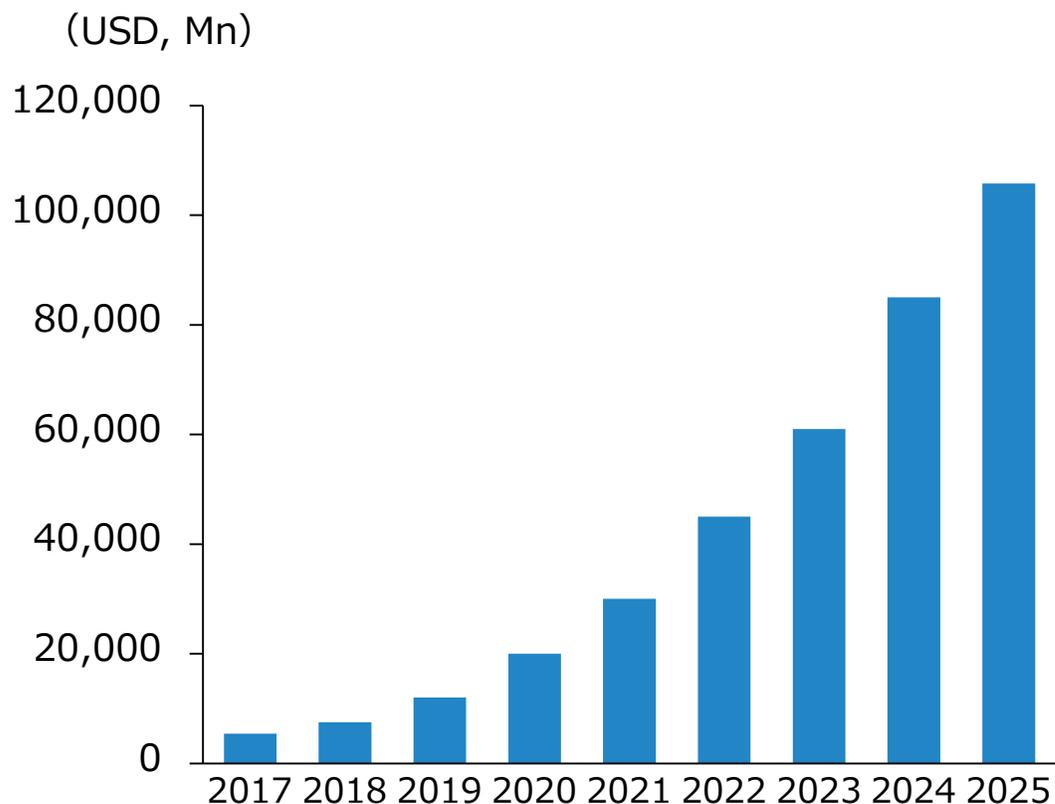
ビジネス・技術双方のエキスパート集団

AIの注目度と日本の現状

AIを取り巻く環境：市場規模

“AI”は世界的に最も成長が期待されている市場
日本も大きな成長が見込まれている

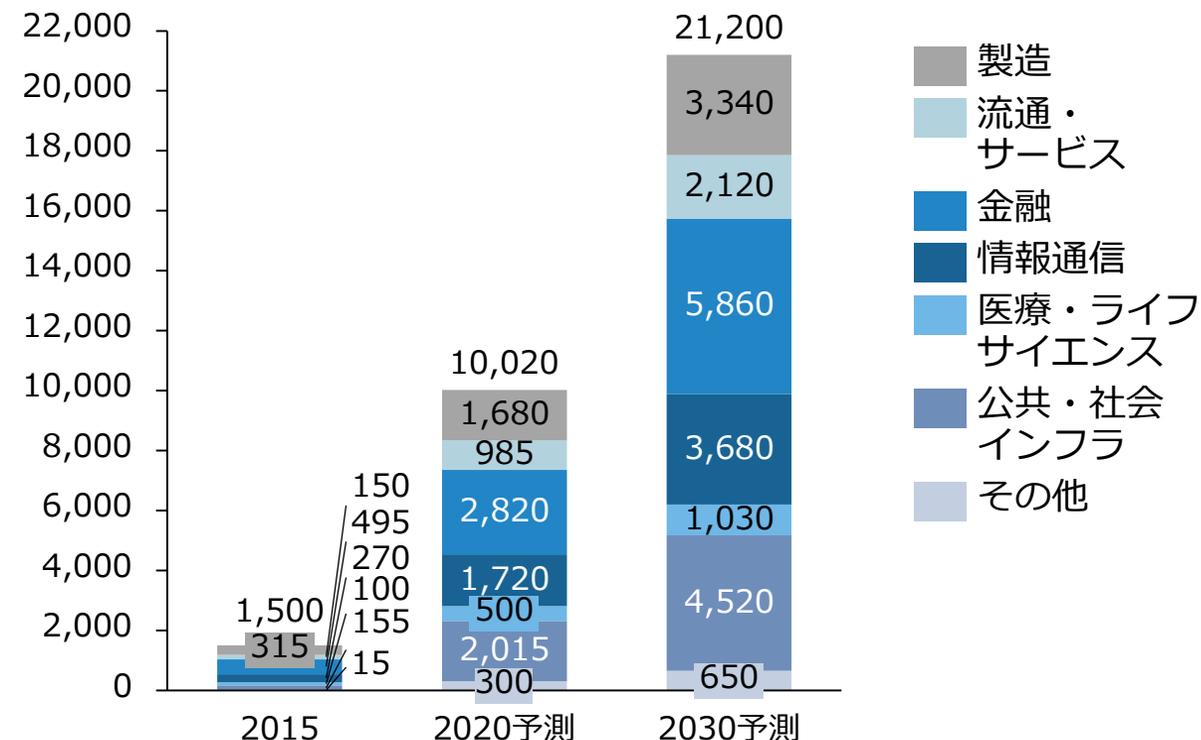
AI市場規模



Source: Tractica “Artificial Intelligence Market Forecasts”

日本のマーケット

国内AI市場規模（億円）

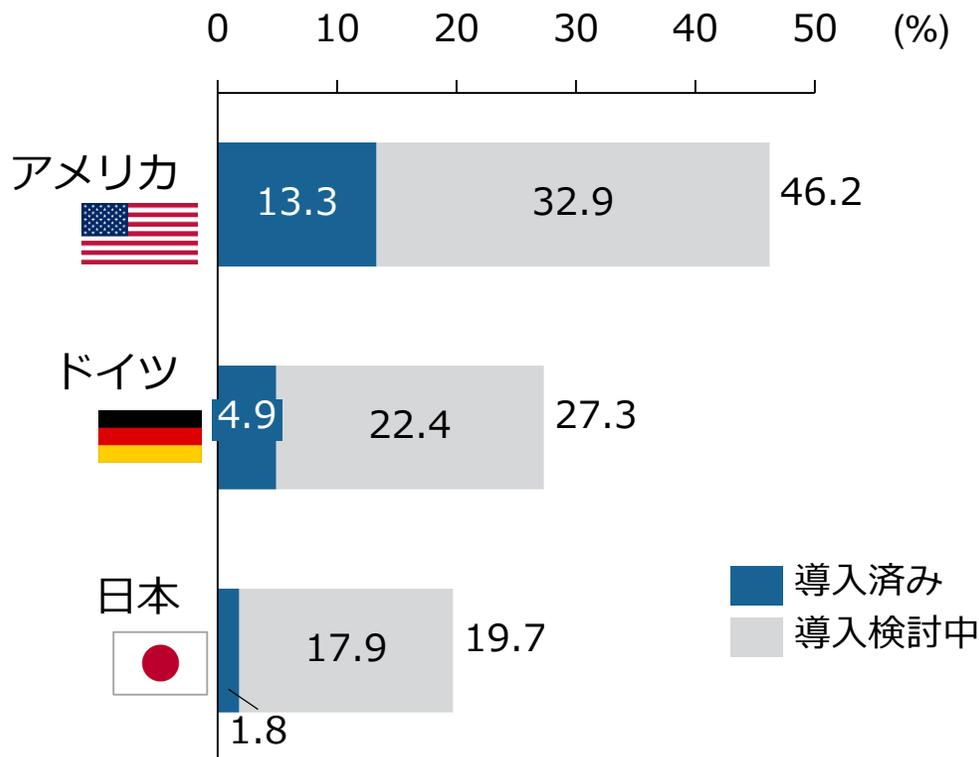


AIを取り巻く環境 日本での市場動向

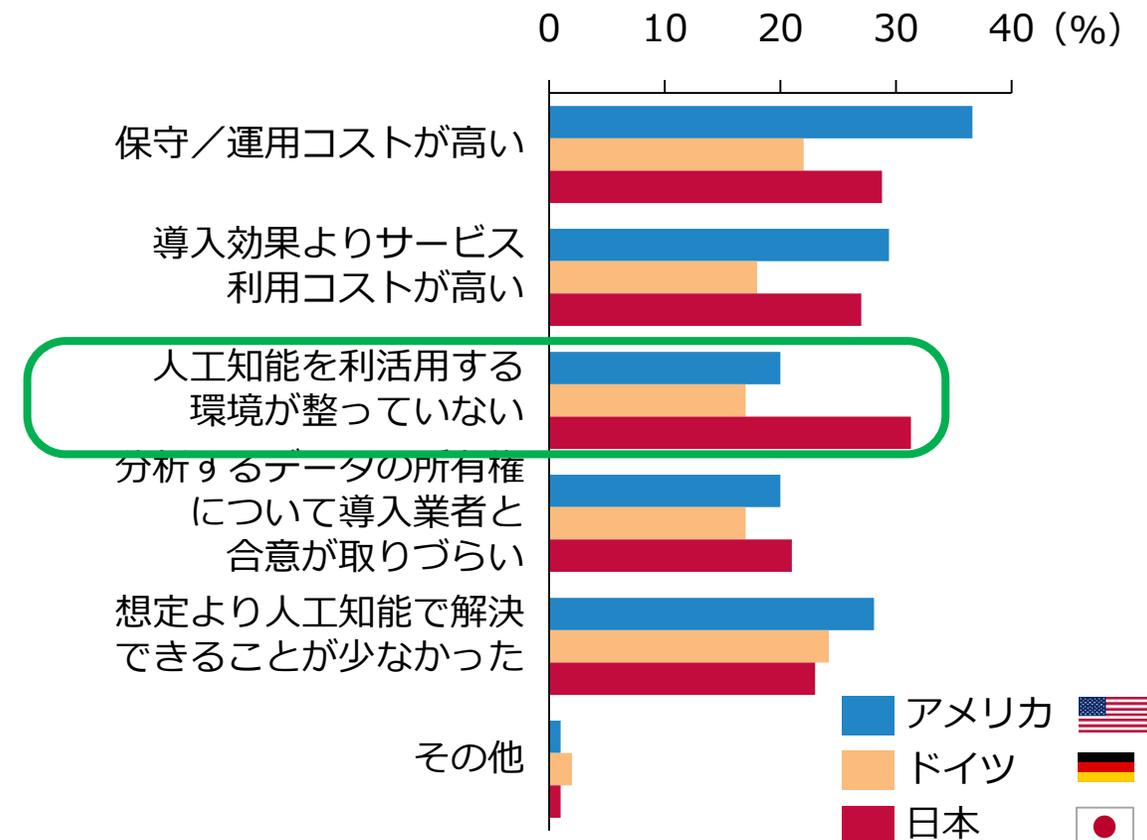
(I) 導入率と課題

一方で、日本でのAI導入率は低い。
他国はコストが阻害要因だが、日本では環境準備に課題がある状況

各国のAI導入率



導入の阻害要因

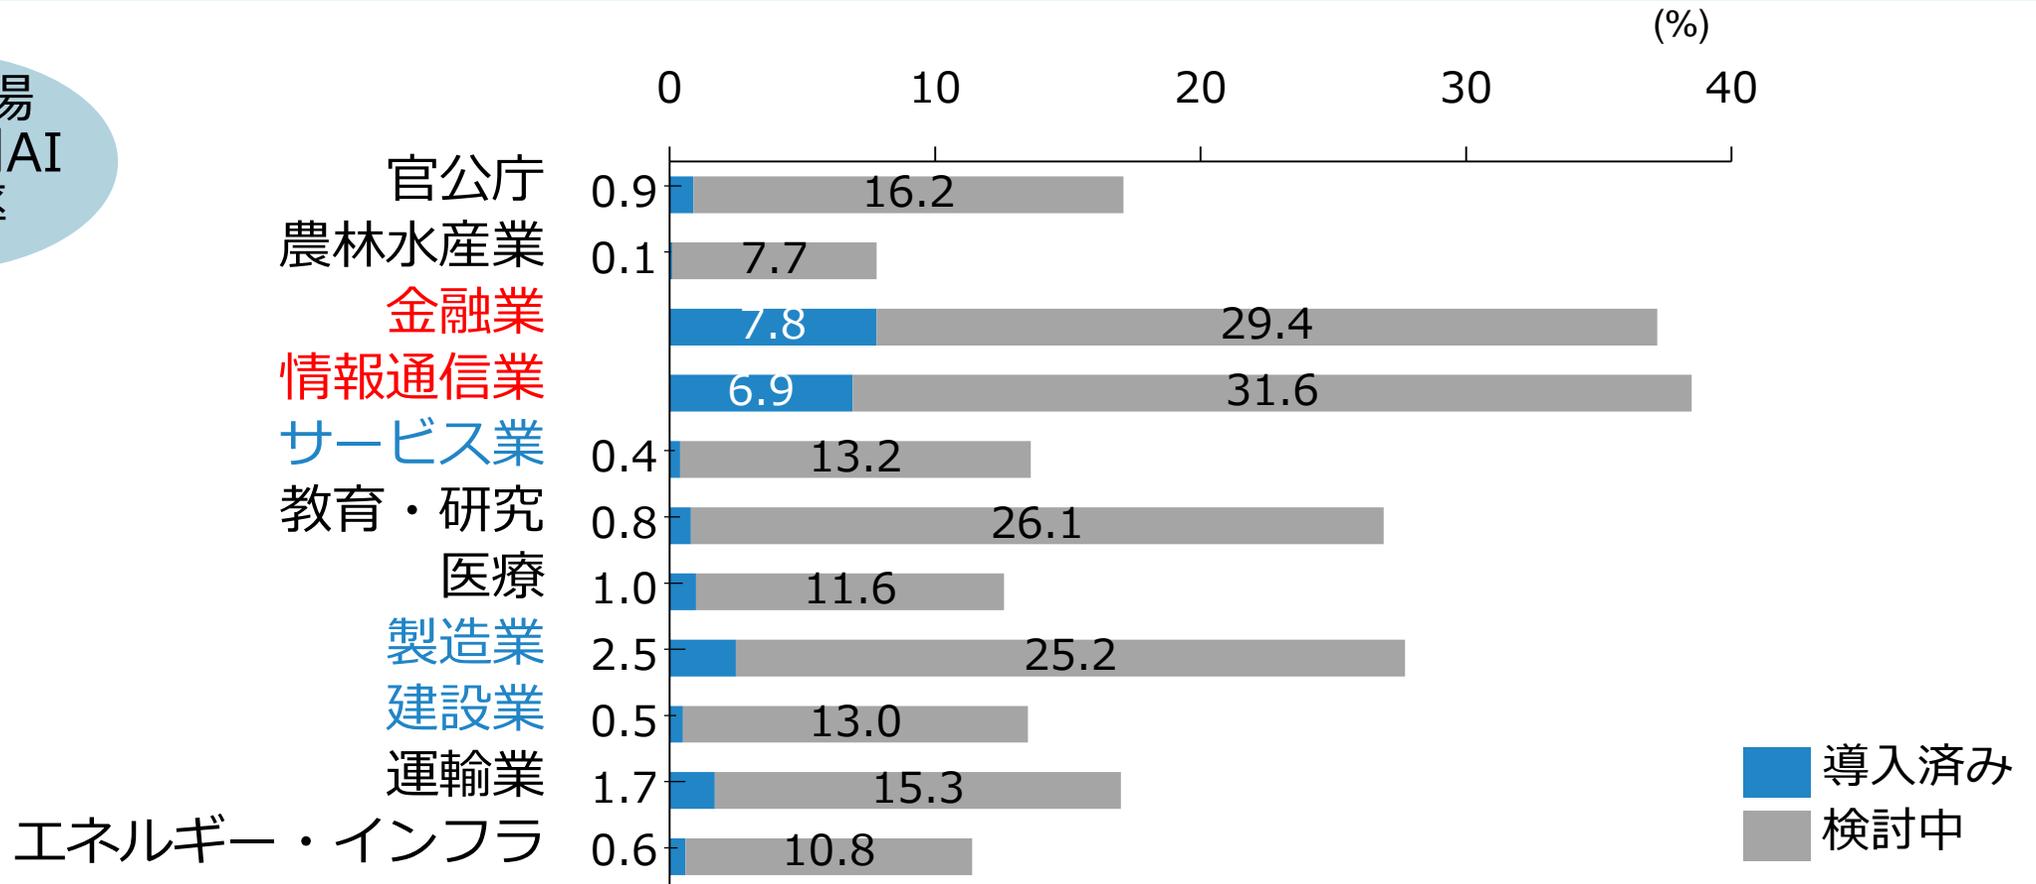


AIを取り巻く環境 日本での市場動向

(II) 活用分野

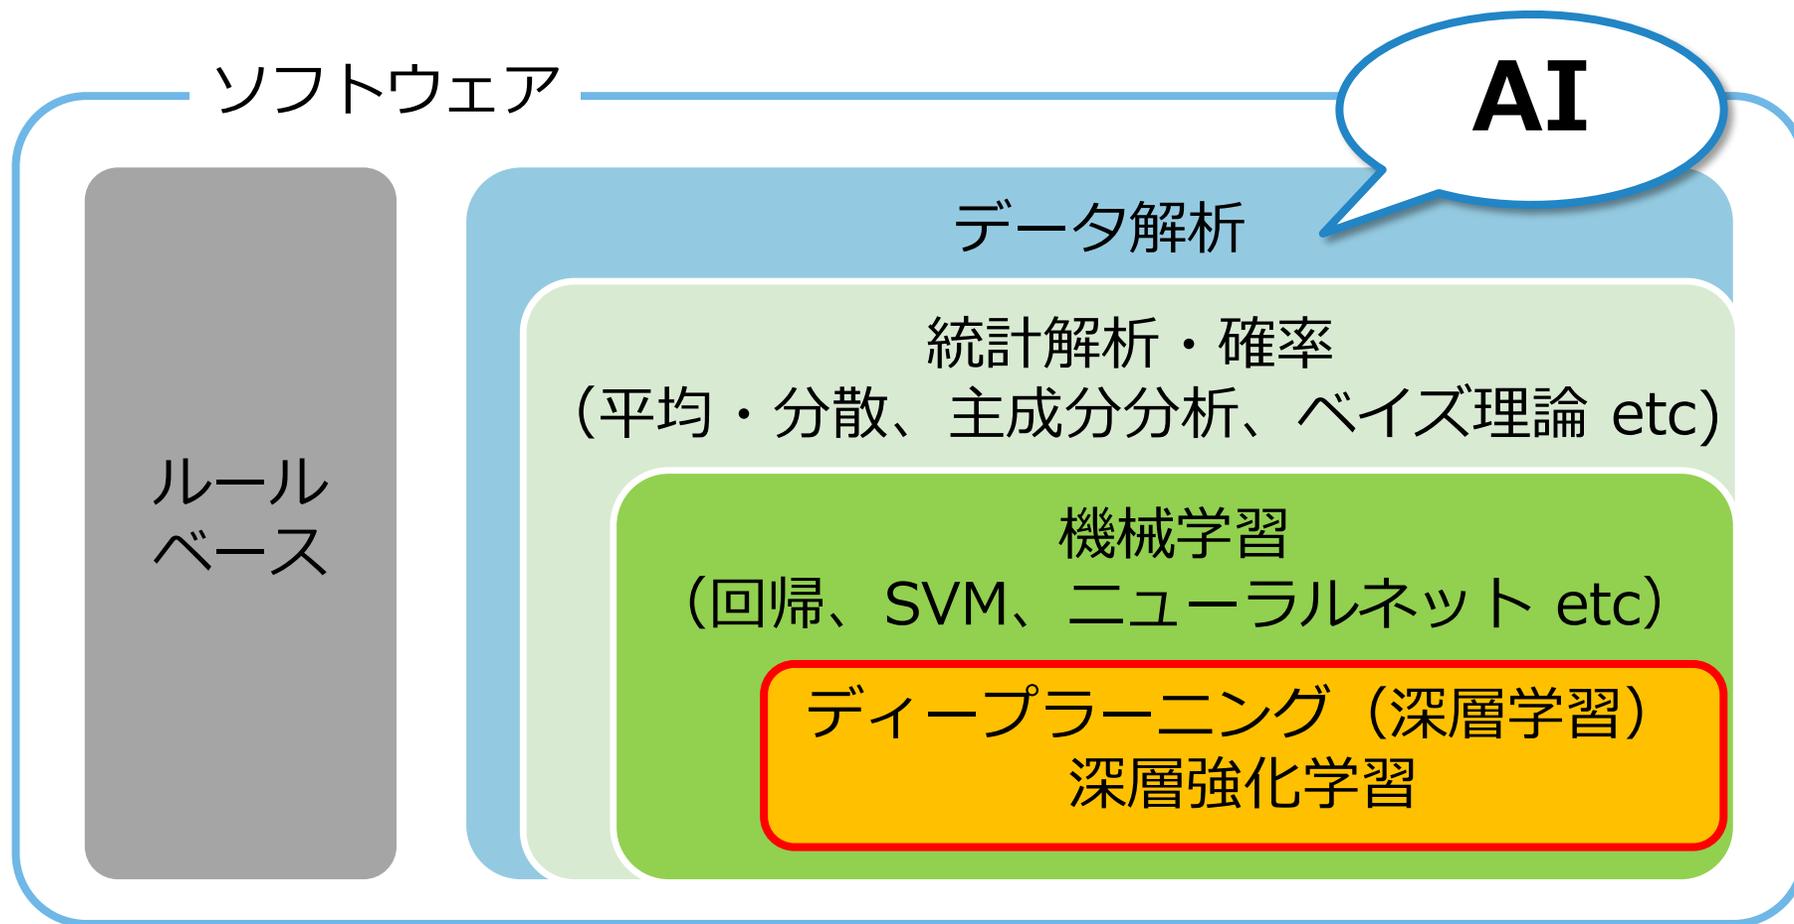
金融・ICT以外でAI導入はほぼ進んでいない。
日本のGDPを占める製造業・建築業などへのAI活用の余地は大きい

日本市場
の業界別AI
導入率



私たちのアプローチ

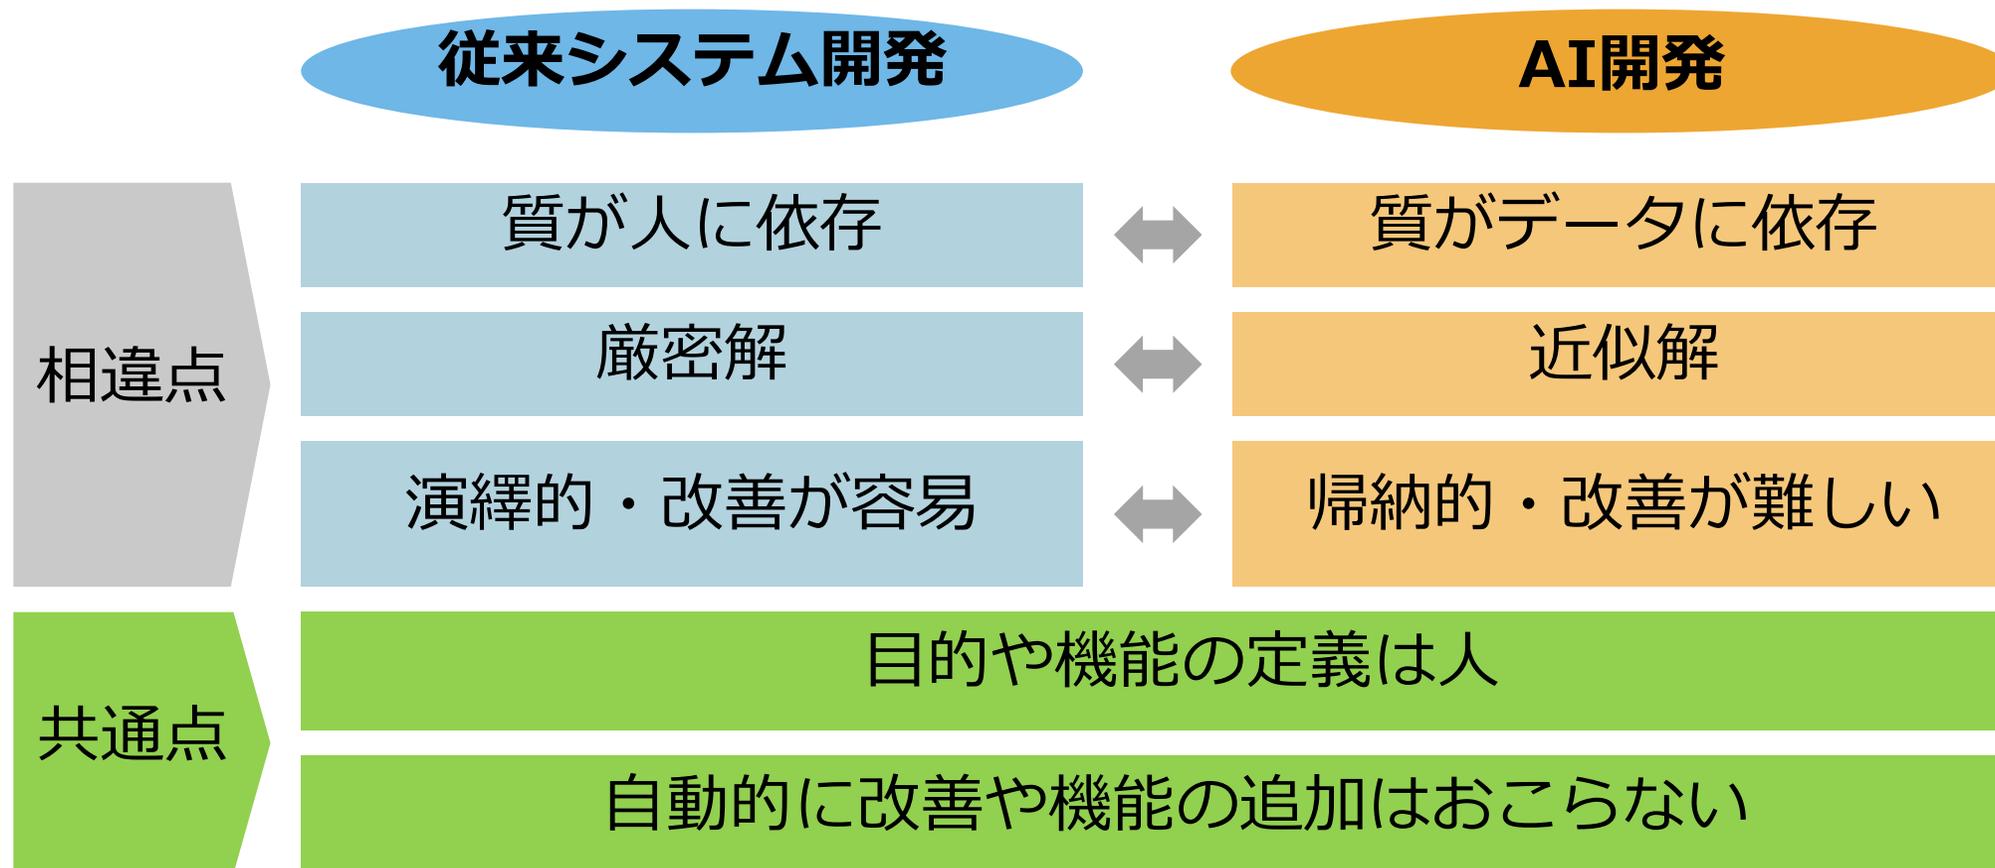
AIの定義のあいまいさ



※強化学習、最適化問題なども仲間入り

AIとは? の混乱をほぐすことからスタート

AIと従来システムは長所短所の関係



従来のシステム開発 と AIを組み合わせたベストミックスを提案

アセスメント～開発・導入まで ワンストップで支援

開発判断

導入判断

Phase-0
AIの正しい
共通理解
醸成

Phase-1
AI導入効果アセスメント・
パイロット検証

Phase-2
本格開発・実証実験
システム連携

Phase-3
運用・改善
横展開

経営層・
関係者
向け講義

要望棚卸
AI/非AI
仕訳

AI導入
目的・
課題
の整理

データ
とAIの組
合せを定
義

AIパイ
ロット
検証

AI
開発・
導入計画
策定

AI
本開発

POC
周辺
システム
との
連携

導入
保守

改善
継続

ビジネスの現場で インパクトを実現

- ゴールを顧客と共に明確化
- AIありきではなくROIを重視
- PoCで終わらず実運用まで社会展開ができる協業体制

卓越した画像解析技術

- 最先端の論文も実装・考案
- 少ないデータで精度を向上するノウハウ
- 競合が達成できなかった案件も複数

総合的なシステム 考案・連携力

- パートナーシップを活かした効果的な開発
- サーバー・FPGA・センサー等ハードウェアの選定支援
- 周辺システムとのつなぎ

これまでの実績（一例）

AIコンサルティング
・ソリューション
開発
(受託)

- 白黒カラー化AI開発
- ごみ識別AIによるクレーン自動化
- 金属表面の異常検知AI開発
- 燃焼状態の動画解析AI開発
- 遠赤外センサー画像解析AIを用いた自動制御システム開発
- 衛星レーダー画像を用いた作物解析AI開発
- 衛星レーダー画像を活用した海上オイルスリック検出AI開発

共同製品開発

- 白黒映像カラー化AI
- 複数カメラ対応 同一人物認識 AIカメラ（大手通信企業と共同開発中）
- 製造業向け 静止画・動画 異常検知AI（リコー社と共同開発中）

新規事業創出支援
オープン
イノベーション

- 荏原環境プラント様 ごみ識別AI技術を基にした新規事業創出支援
- リコー様 異常検知AIの新規事業創出支援
- 大手通信業 同一人物認識AIカメラの新規事業創出支援

弊社事例紹介

目的に応じてカスタマイズしたAIを提供します

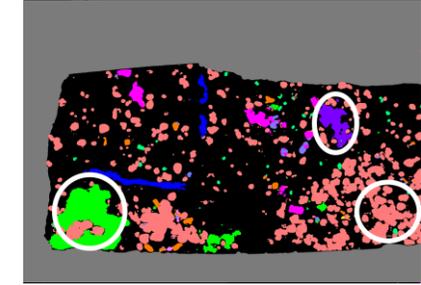
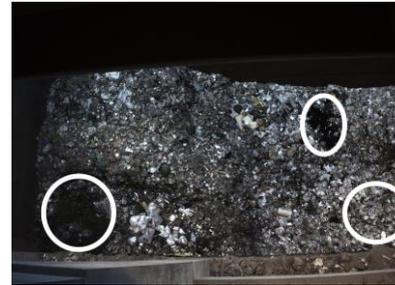


想定利用シーン

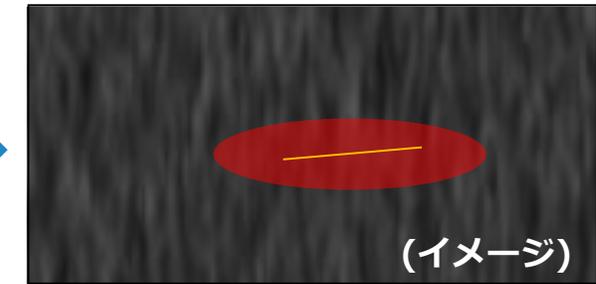
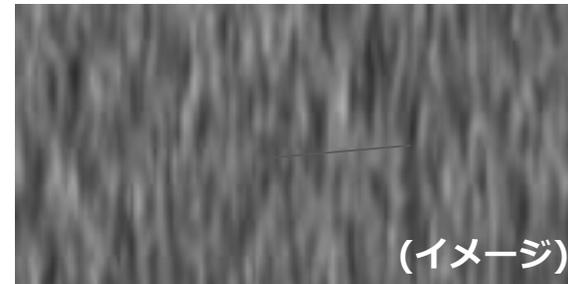
解析画像

解析結果

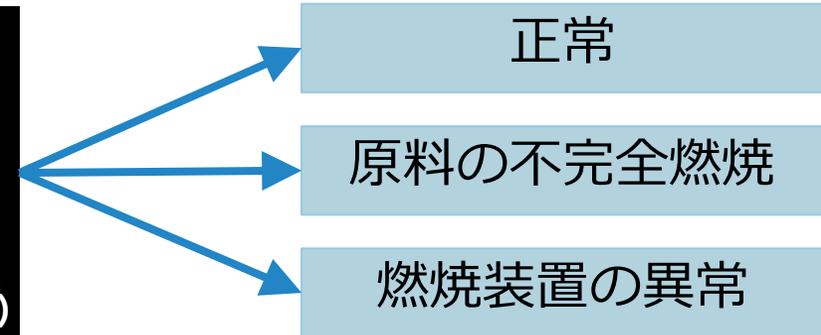
① 高精度でのごみ分別



② 高解像度での製品表面のキズ・ゆがみ検出



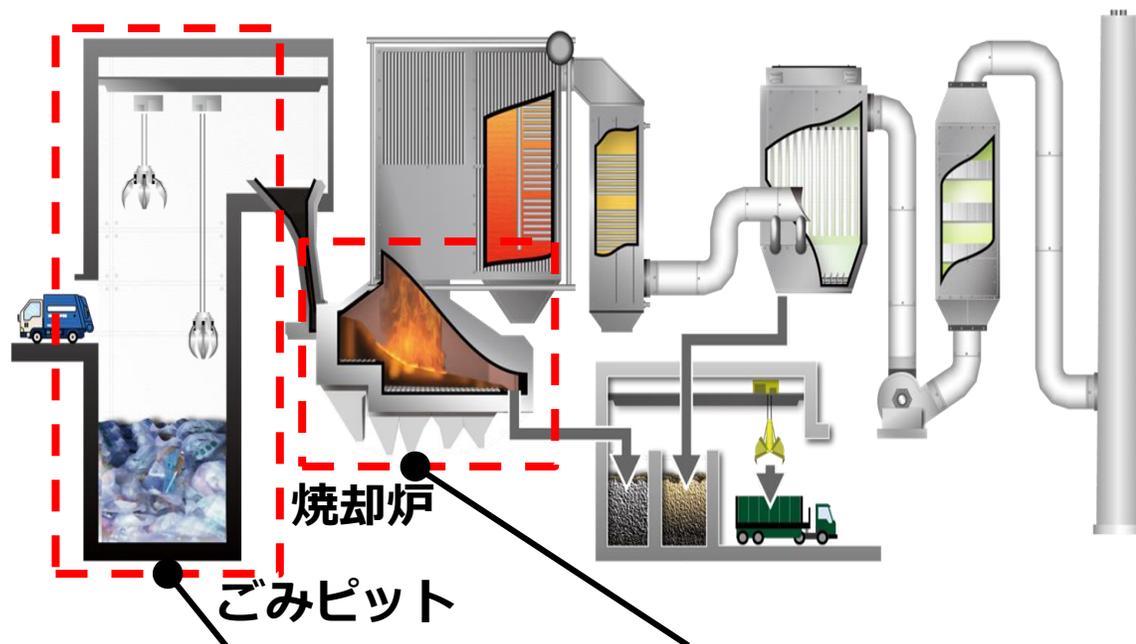
③ 動画でしか判定できない 燃焼状態の異常判定



高精度でのごみ分別

ごみ焼却炉でのセグメンテーション活用
荏原環境プラント株式会社様と共同開発

ごみ焼却炉イメージ図



<クレーン操作室>



<燃烧状態を監視する中央操作室>

課題と目的

従来の自動運転では投入する
ごみ質の変動が大きく、
安定した燃烧ができない



ごみの質をピクセル単位で認識
することに成功

熟練オペレータのノウハウを
再現し、既に自治体で稼働中

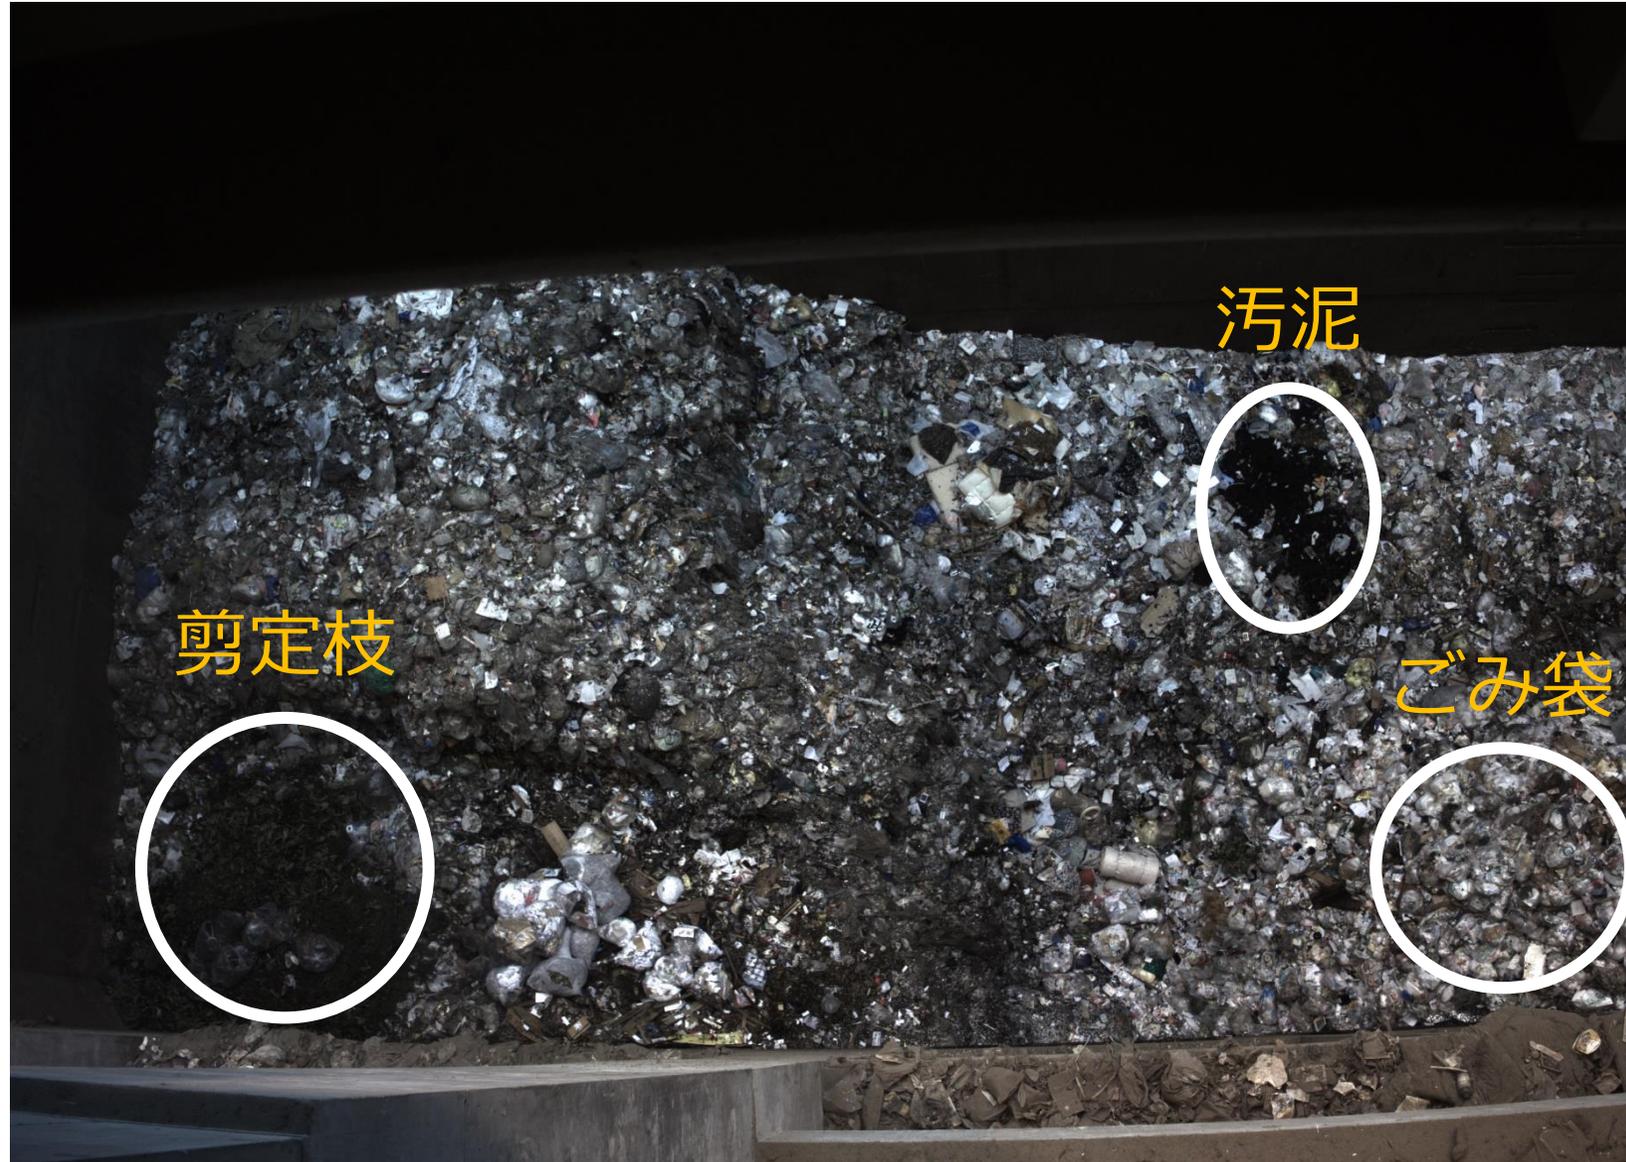
自治体で実運用中 ごみ焼却炉AI搭載自動クレーン

[動画はこちら](#)

ごみ焼却施設における AI(人工知能)活用

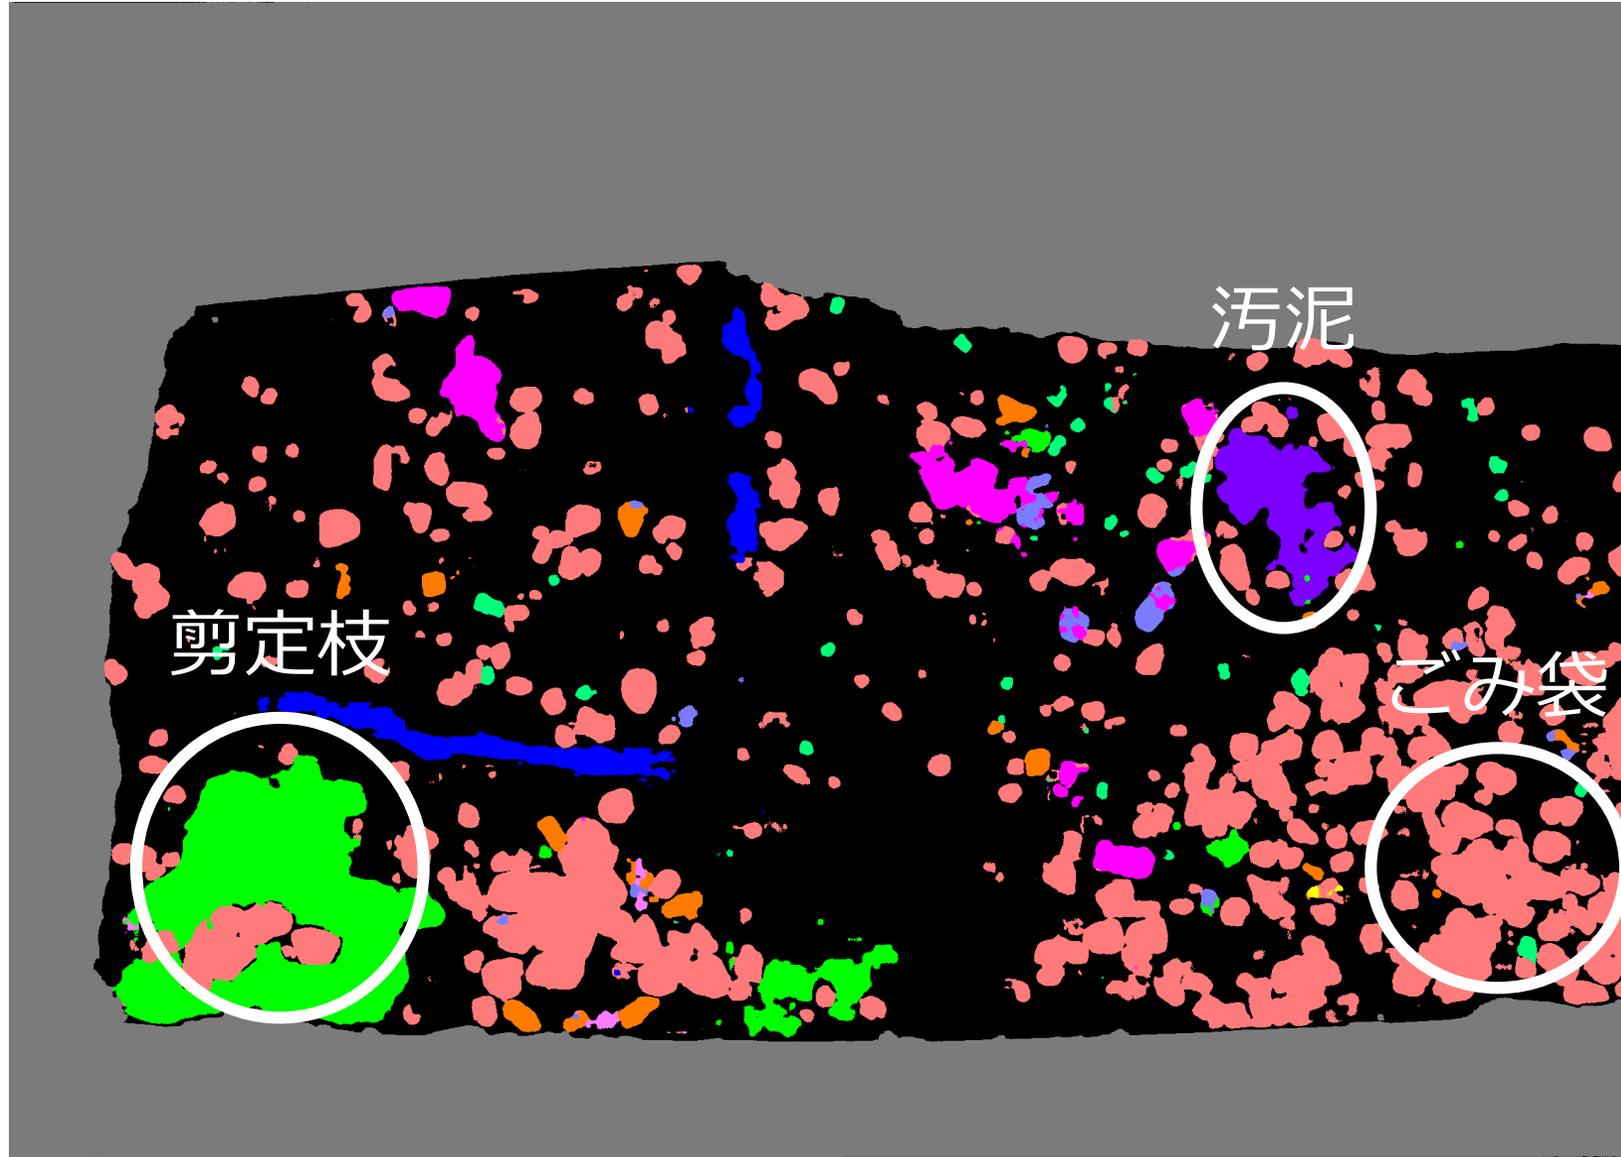
高精度でのごみ分別

ピクセル単位で物の識別が可能



高精度でのごみ分別

ピクセル単位で物の識別が可能



放送実績あり 白黒映像カラー化 ディープラーニング



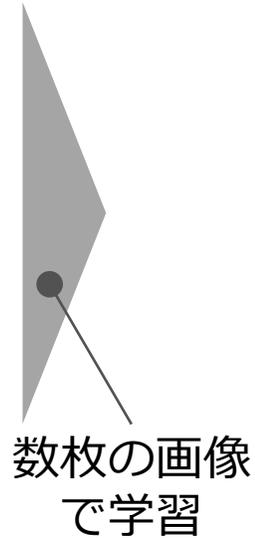
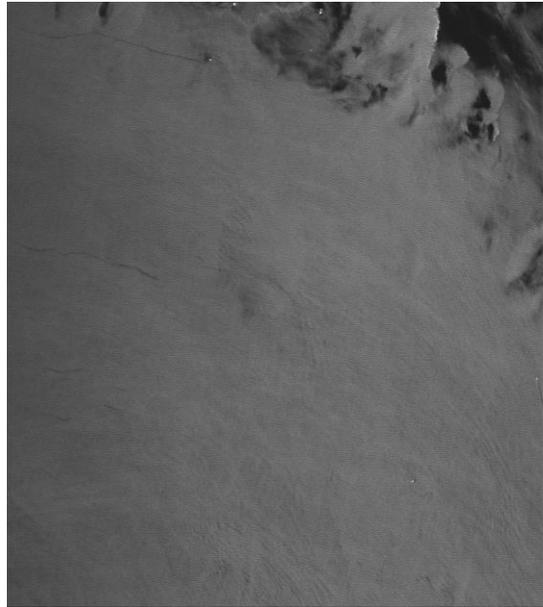
放送実績

- 「第50回 思い出のメロディー」 2018/8 NHKで放送
- NHKスペシャル「戦後ゼロ年東京ブラックホール 1945-1946」 2017/8 NHKで放送
経済産業大臣賞 VFX部門を受賞
- 大相撲「カラーで蘇る名勝負」 2017/5 NHKで放送

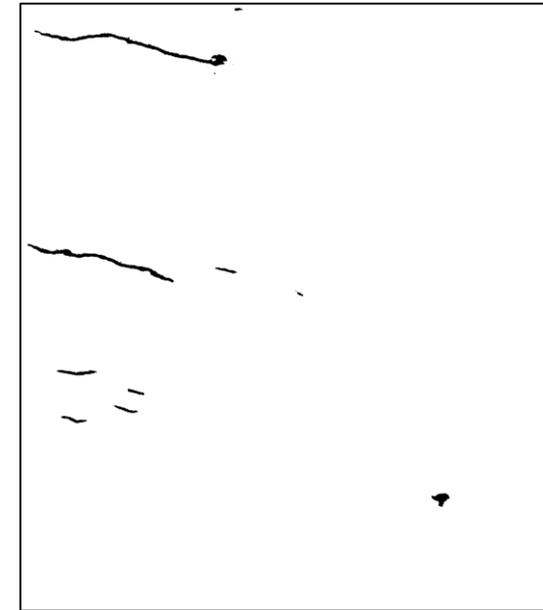
衛星レーダー画像 オイル流出検出



レーダー画像



AIによる解析



- ルールでは波とオイルは分類困難
- 読み解けるのは一部のエキスパートのみ

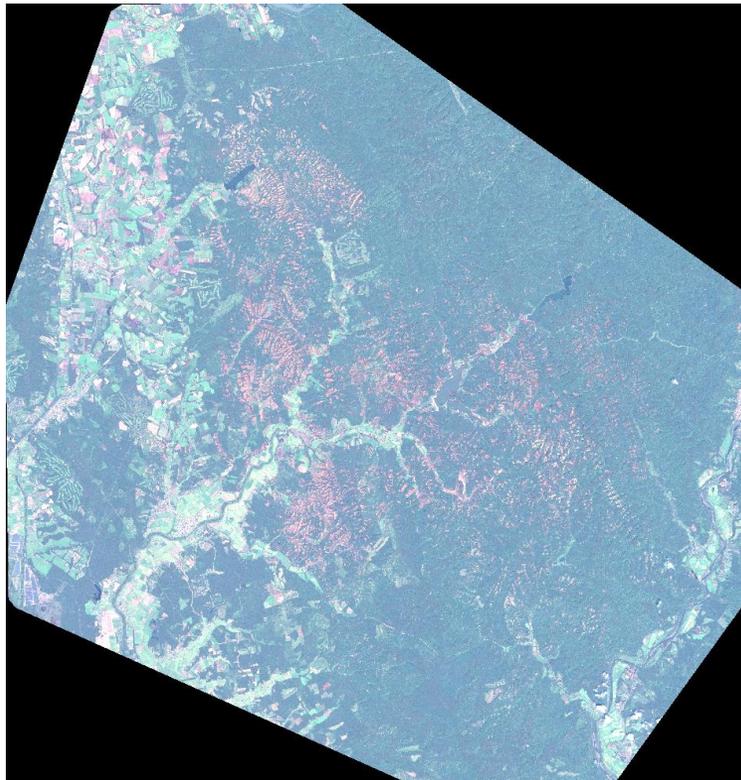
- AIの活用により、オイルスリック（油膜）があるエリアを高精度で特定

衛星データは未解析×大量で
ディープラーニングと相性が良い

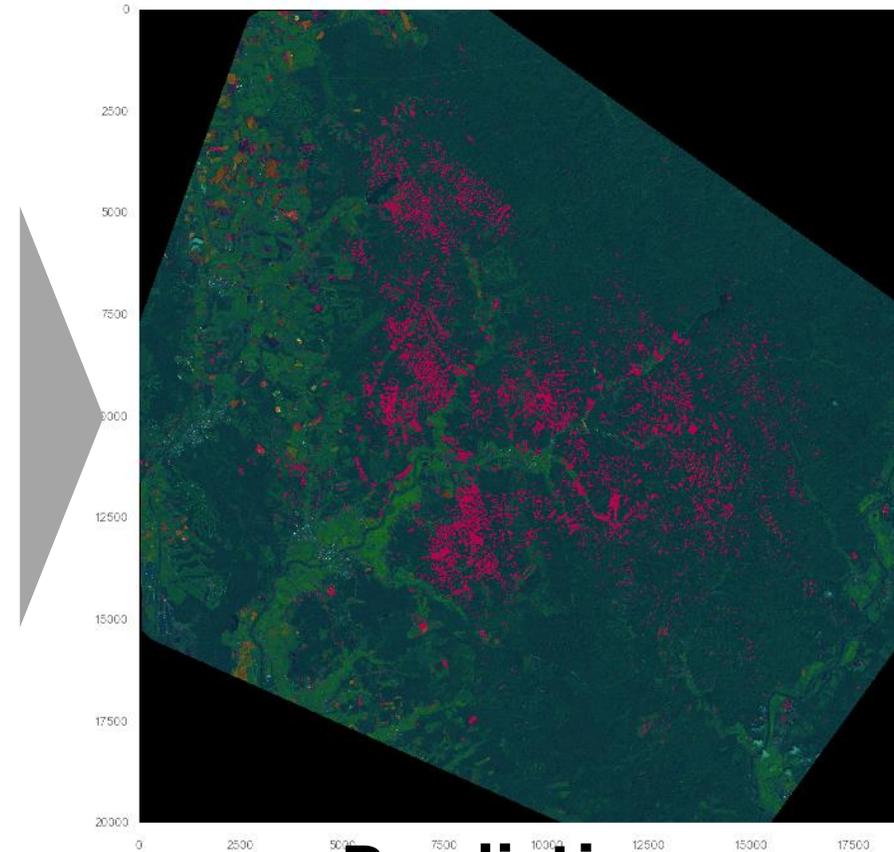
衛星データ 土砂崩れ ディープラーニング検出



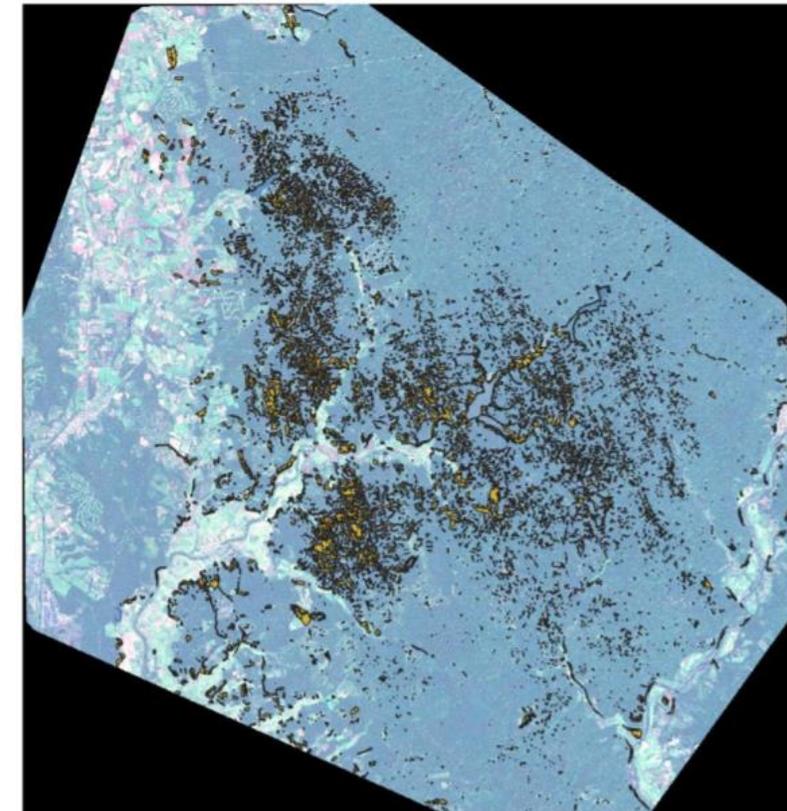
JAXAから解析依頼
北海道胆振東部地震により土砂災害が発生した地域を、
ディープラーニングでMean IoU 80%超で検出



※衛星 SPOT 6



Prediction



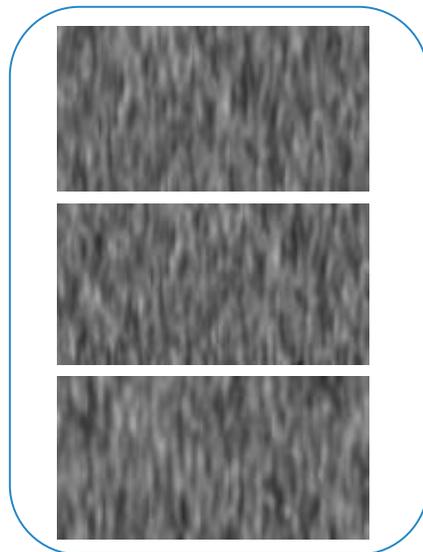
Ground truth

高解像度での製品表面のキズ・ゆがみ検出

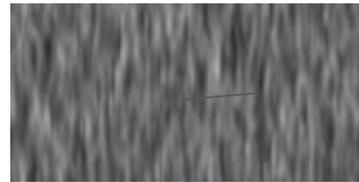


異常検知の課題 不良は定義が難しい、数がすくない、アノテーションが難しい 等

学習用の良品画像



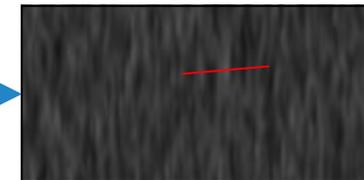
検品画像



良品画像の
特徴を学んだ
DL

不良判定

良品には存在しなかった
キズ・ゆがみなどを検出



良品画像のみを使った異常検知がディープラーニングで可能

高解像度での製品表面のキズ・ゆがみ検出

異常検知の実用化に向けておきた課題と対策



データ

- 完全な「良品」の定義が難しい
- 良品データ自体のばらつき (取得時期・振動 etc)
- データ数の不足 (例: 初回検証が数百枚程度)

不良データで精度もあげる独自ロジック (論文採択)

求められる精度

- 高解像度を維持する必要性
 - 低解像度で消える微細な傷
 - 全体を見て判断する必要
- 異常箇所をピクセル単位で表示
- 通常のGANだと、高解像度の学習が収束しない

Anomaly Detection GAN + 高解像度化の論文実装

処理速度

- PCサーバーでは学習に数週間かかってしまう
- 高解像度NNがメモリに乗り切らない

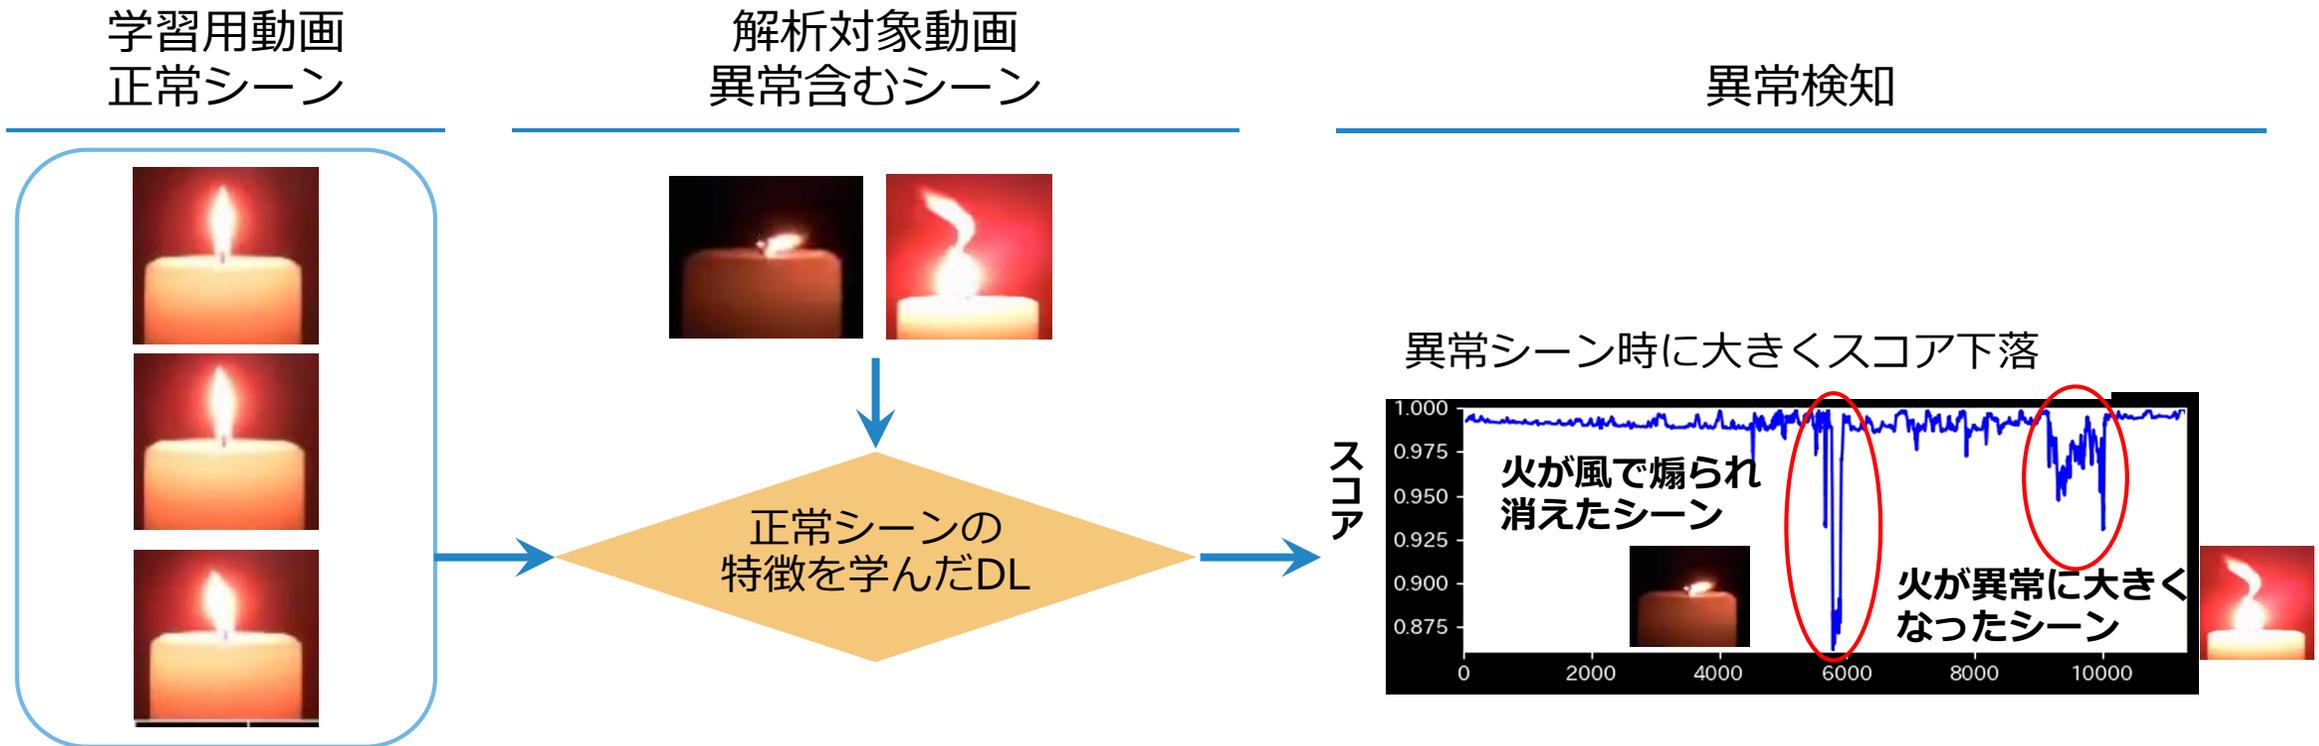
推論環境を複数検証 JETSON、クラウド、オンプレ

対象物／不良の特徴に合わせて最適な手法を提案可能

動画を用いた燃焼状態の異常検知

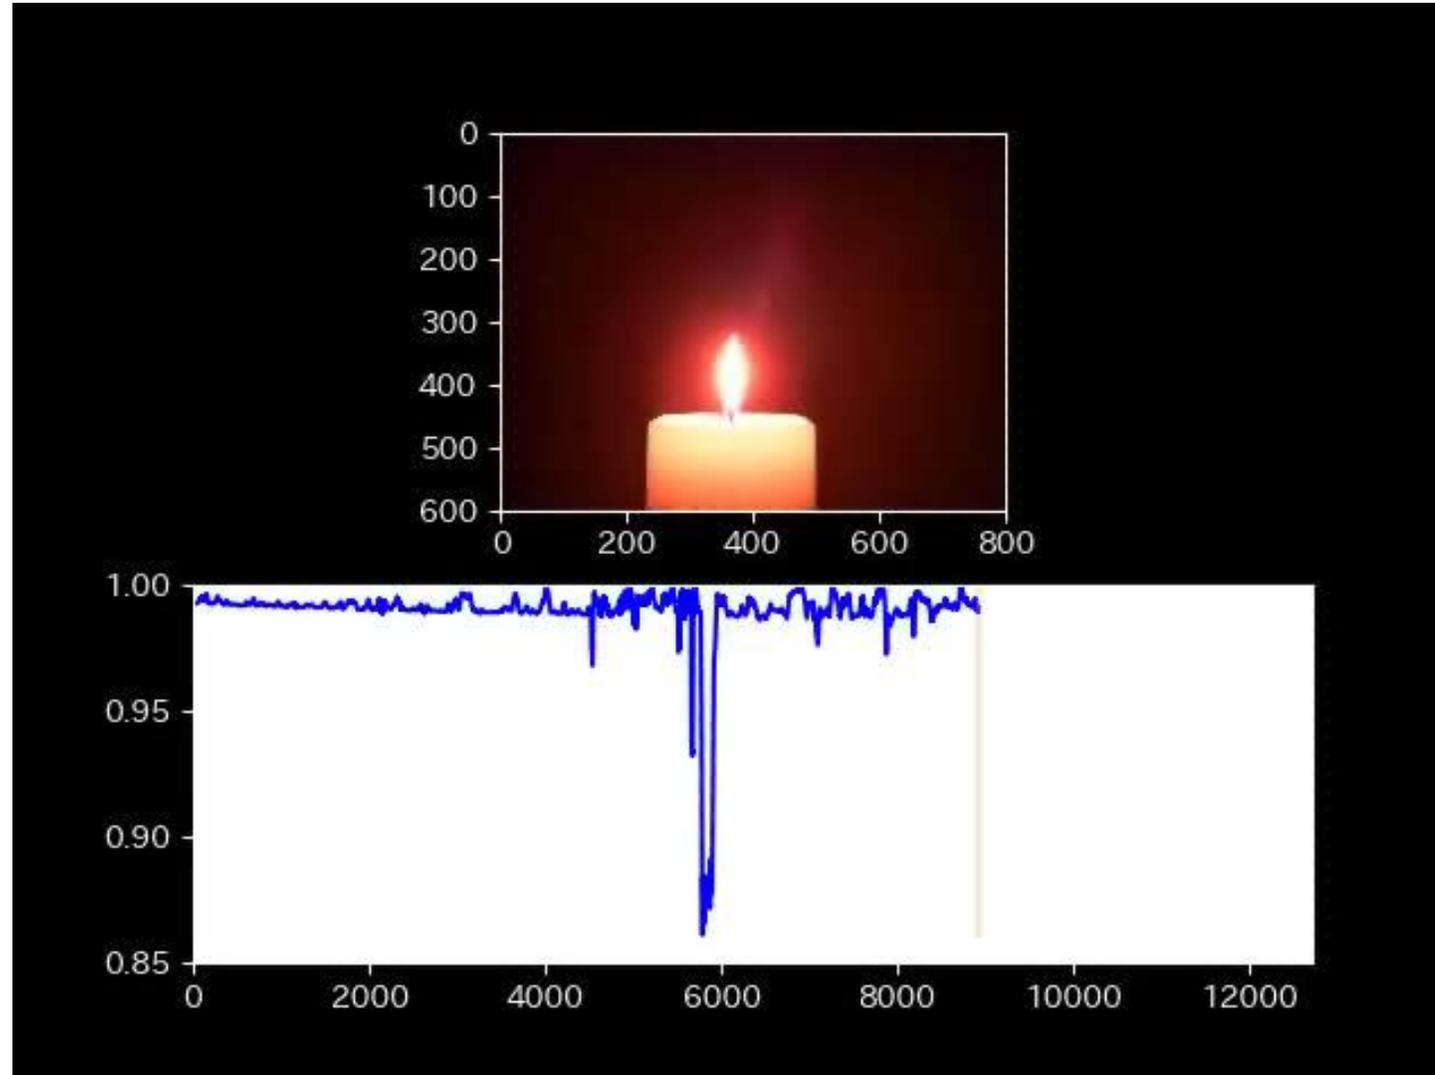


静止画では検知できない、動態からの異常検知技術を開発し、
燃焼状態の異常検知を実現



- 正常シーンのみを使い、燃焼状態の異常検知を高い精度で実現
- 動画によるシーン分類も開発実績有り

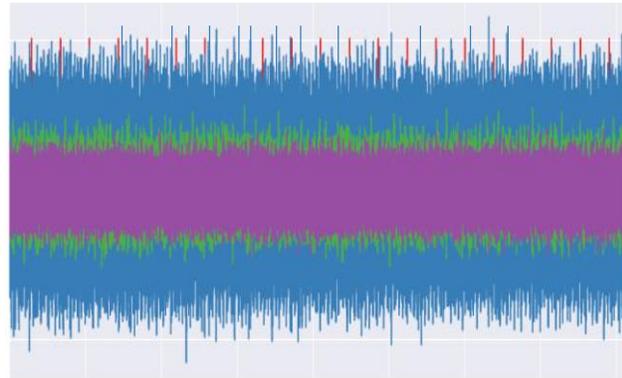
動画を用いた燃焼状態の異常検知（検証動画）



波形データから故障兆候を検出

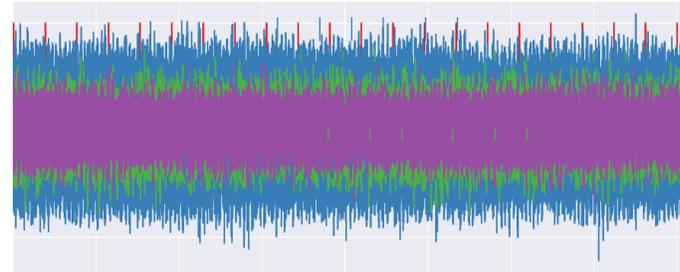


学習用の正常波形



検証波形

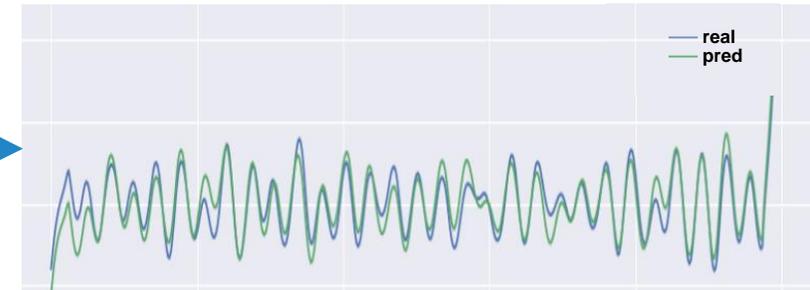
Fig2. Abnormal data



不良判定

学習したデータには
存在しない特徴を検出

Fig8. Prediction for abnormal data(sensor=3,
n=600)



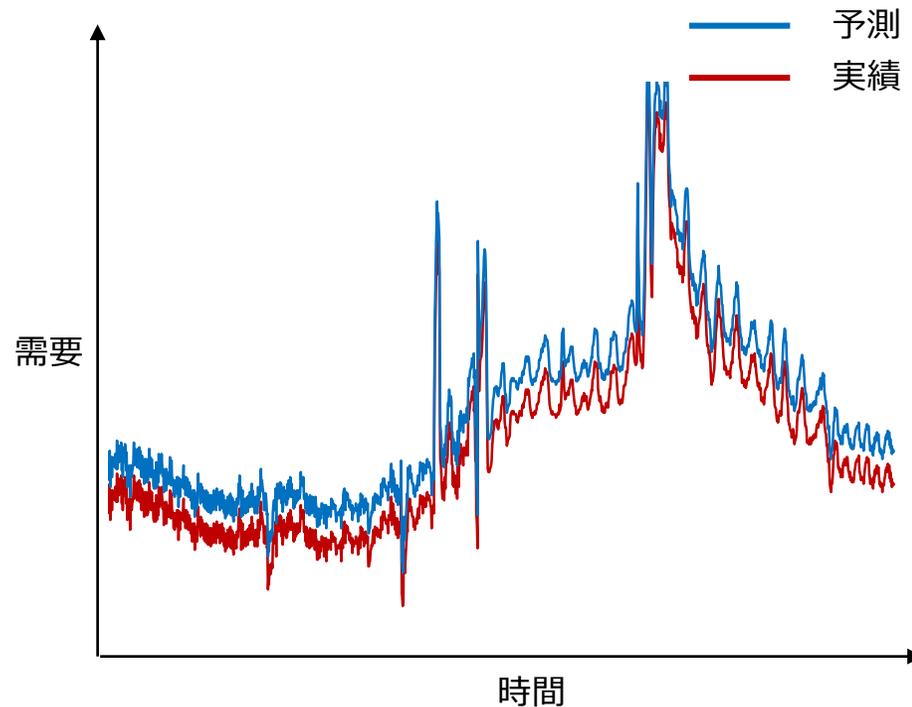
正常波形
の特徴を
学んだAI

すでに実振動データを使った故障予知に成功

需要予測 & 機器の自動操業



製品需要に関する変数に基づく
直近の需要予測



生産機器の自動運転制御

時間	機器A	機器B	...	機器X
t	状態1	状態2		OFF
t+1	状態1	状態2		OFF
t+2	状態2	状態2		状態1
⋮				
t+N	状態2	状態2		状態2

所定の時間における、効率的な機器の操業状態を決定

- 1日の中で刻々変化する需要をAIで予測
- 需要予測に基づき、最適な生産機器の組合せと各機器の操業状態を決定し自動制御

映像解析の活用例 同一人物の認識

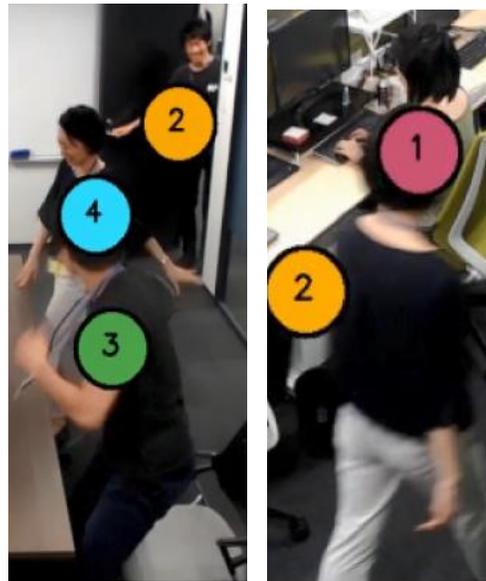


- 服を脱ぐ、マスクを取るなどでも同一人物と判定
- 人が重なる難しいシーンでも、きちんとトラッキングが可能
- 複数カメラをまたぐ動作でも導線の追跡がリアルタイムに可能

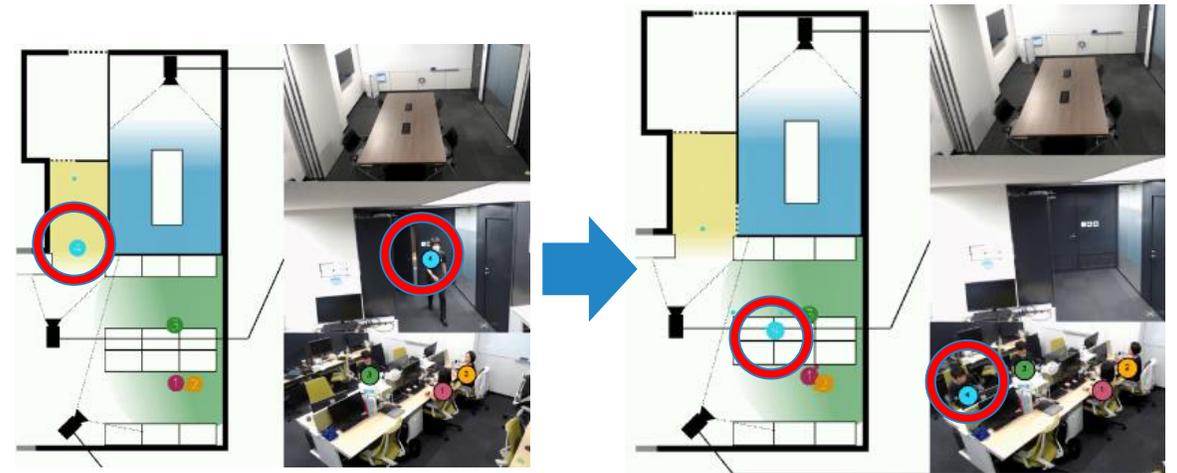
服装変化に対応



重なりにも対応



カメラまたぎの導線追跡



映像解析の活用例 デモ



<技術領域>

- **動画対応の異常検知**
 - 燃烧反応、対流、異常行動 …
- **目的特化のエッジAI**
- **3D解析（点群、SLAM）とディープ融合**
- **（より）少ないデータでの学習**
- **テキスト・センシングなど画像以外のデータとの融合**

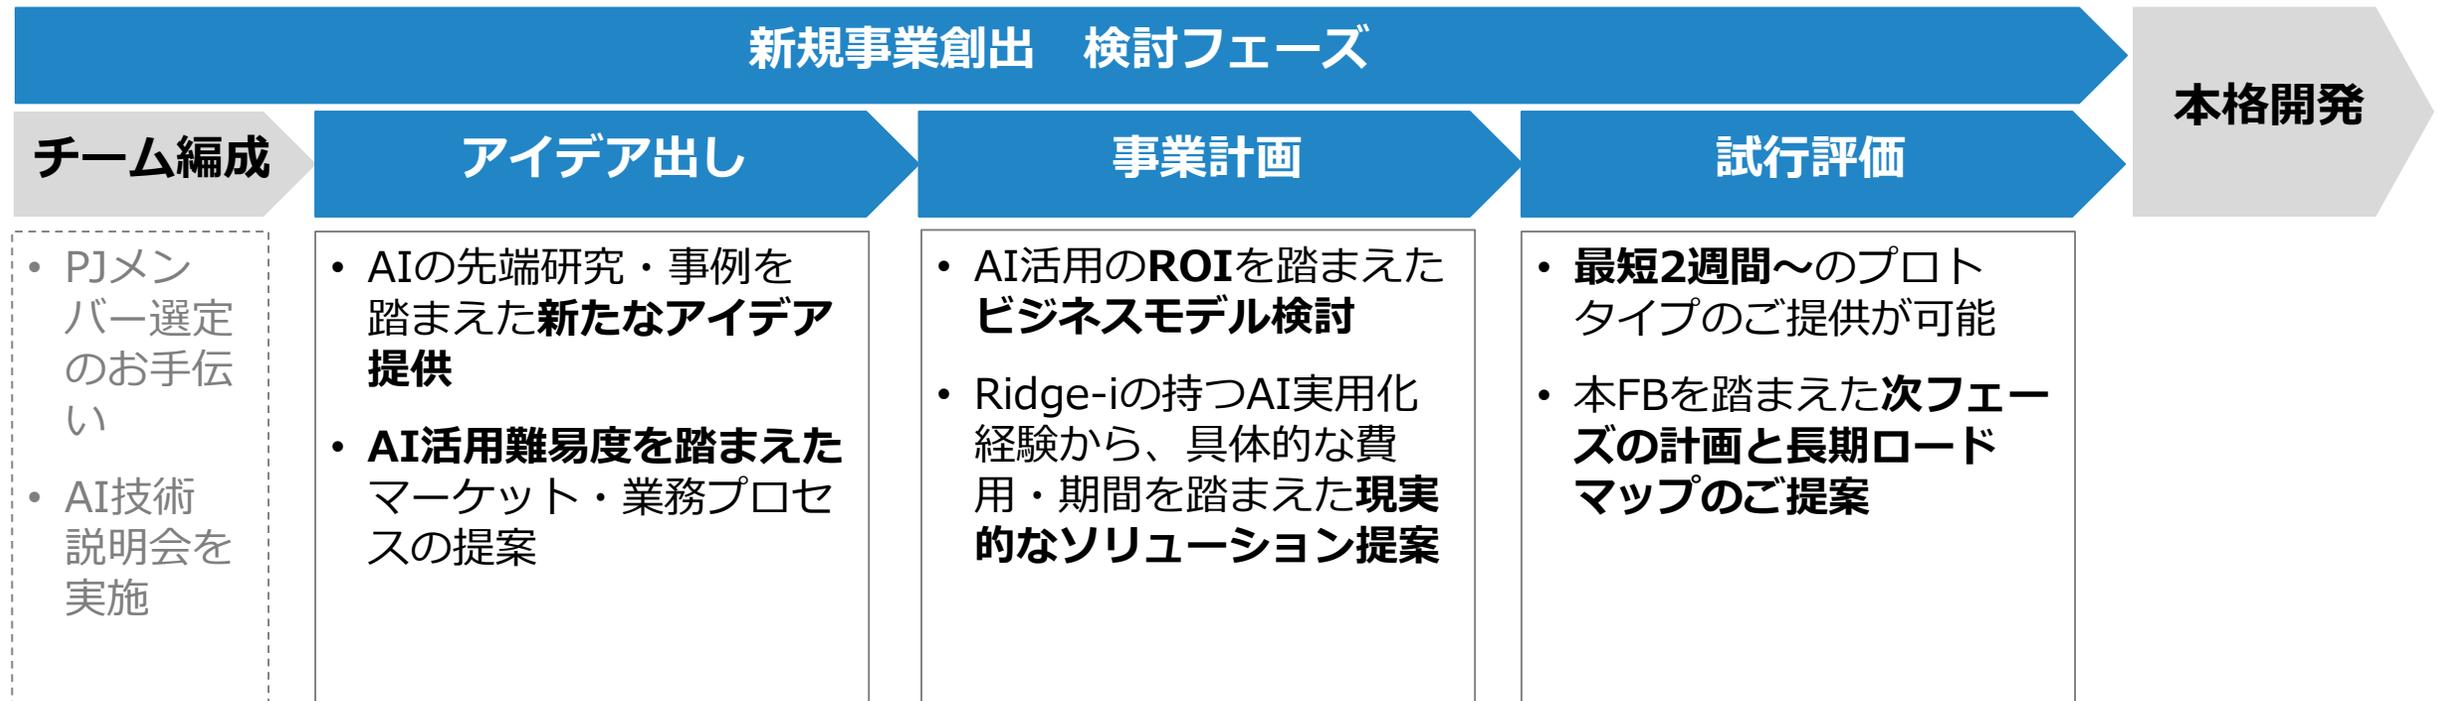
<事業領域>

- **衛星データ解析**
 - 災害検出・予測、マーケットデータ解析 …
- **5Gによる高速・大容量AI推論**
- **大企業との新規事業創出**
 - ブレスト段階から参画

AIを活用した新規事業創出支援



ビジネスと技術双方に精通した専門家が、AIの豊富な導入実績に基づいた知見を提供し、新規事業創出の推進に貢献します



実績

- 荏原環境プラント様 ごみ識別AI技術を基にした新規事業創出支援（試行構築2週間）
- リコー様 異常検知AIの新規事業創出支援（試行構築2週間）
- 大手通信業 同一人物認識AIカメラの新規事業創出支援（試行構築4週間）

AI導入までの課題

個々のフェーズで様々な課題

各フェーズで、ディープラーニング特有の様々な課題が発生

Phase-0
AIの正しい
共通理解
醸成

Phase-1
AI導入効果アセスメント・
パイロット検証

Phase-2
本格開発・実証実験
システム連携

Phase-3
運用・改善
横展開

よく
ある
課題

- 目的と手段の行き違い
- ROIを無視したプロジェクト設計
- 解けないプロジェクト
- AI・ディープに偏った提案
- 実はルールで解決できる
- データの外の情報が実は重要

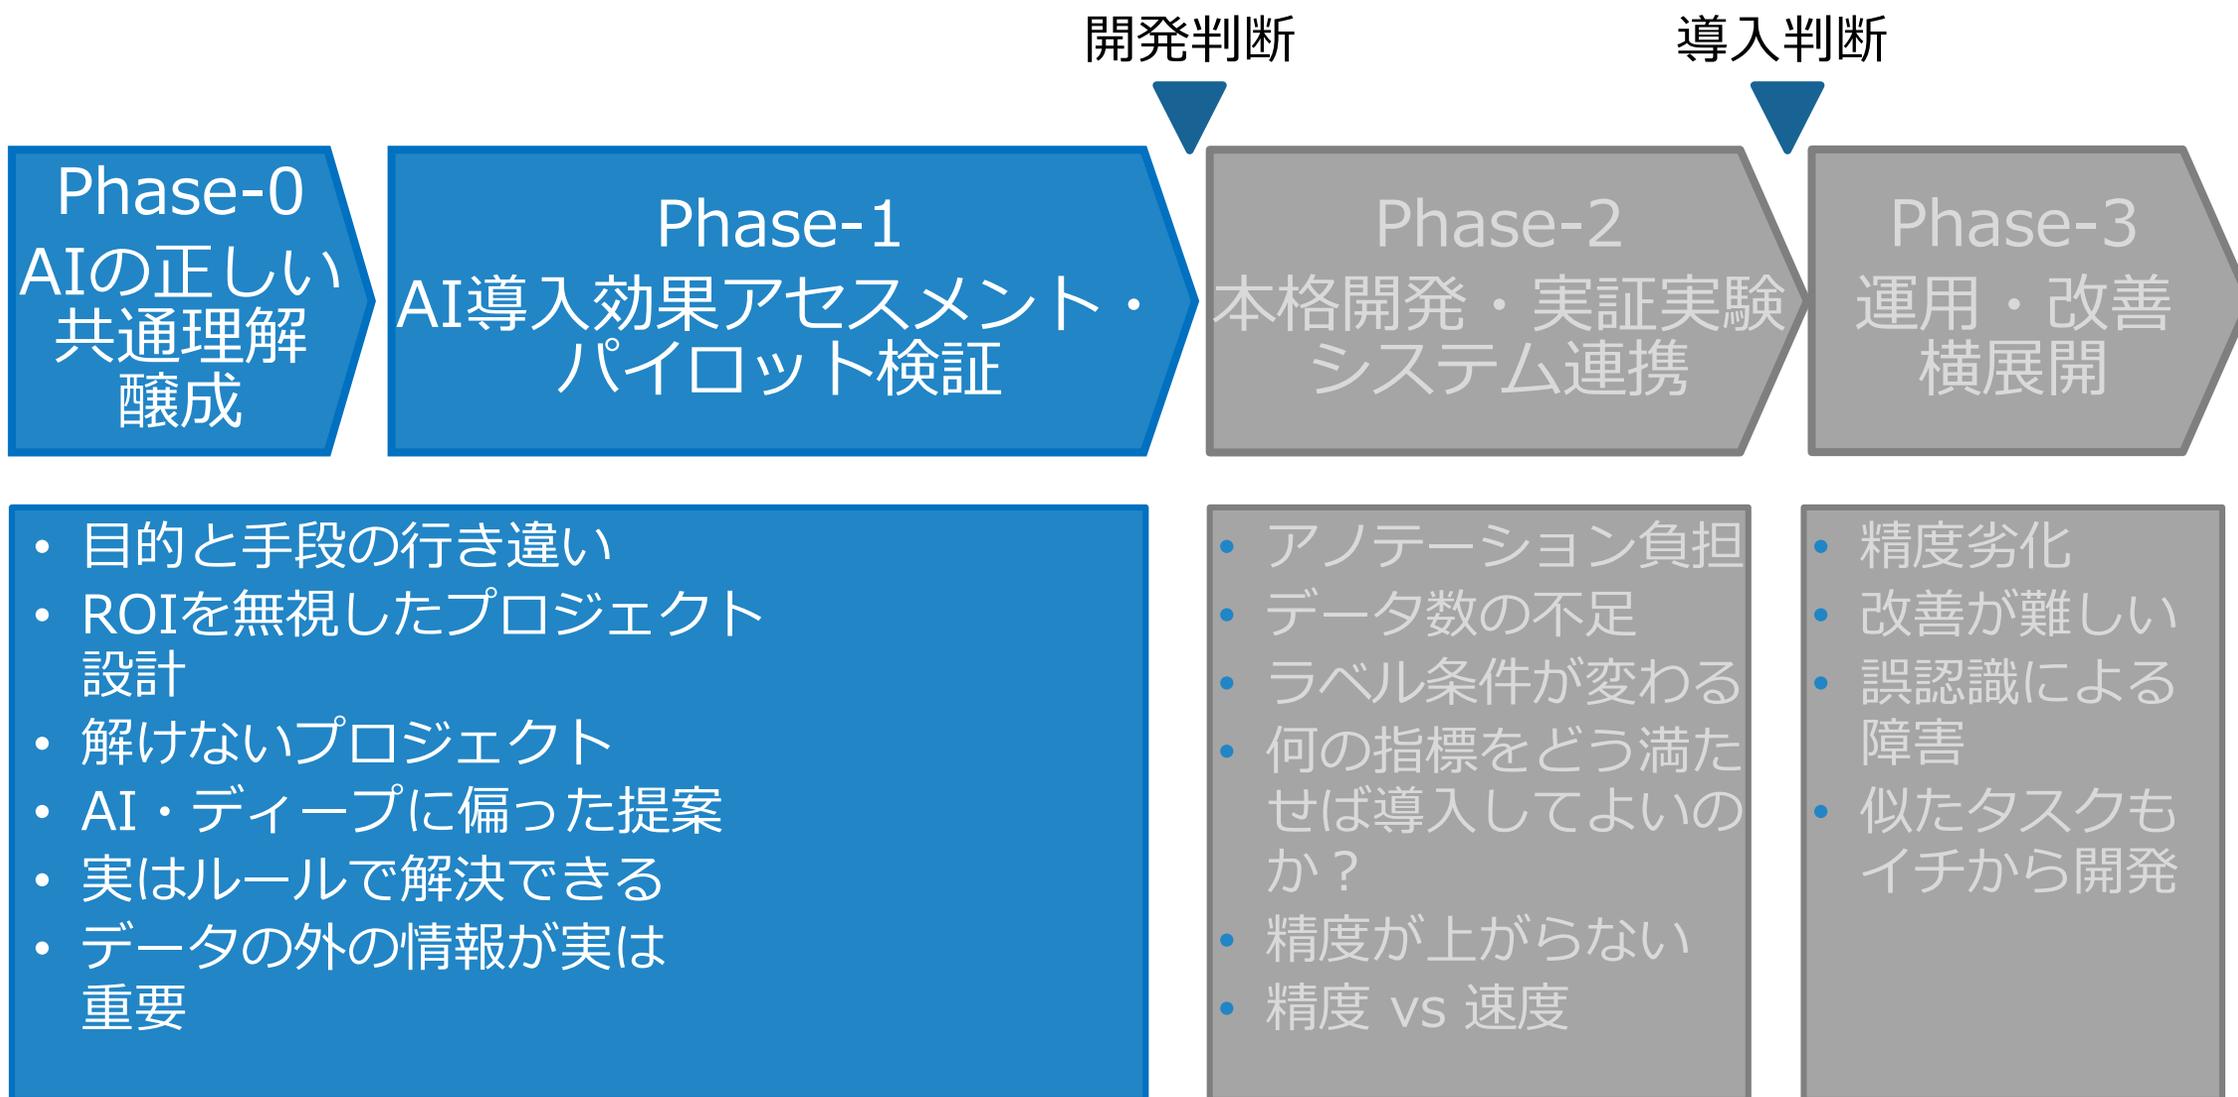
- アノテーション負担
- データ数の不足
- ラベル条件が変わる
- 何の指標をどう満たせば導入してよいのか？
- 精度が上がらない
- 精度 vs 速度

- 精度劣化
- 改善が難しい
- 誤認識による障害
- 似たタスクでもイチから開発

- 目的にあった「ルール×AI」の適切なソリューション設計
- 良いアノテーションポリシーは プロジェクト成功の秘訣
- 導入判断に重要な指標を早めに見つける
- 解析対象の変化を見据えた汎用性
- AIも人も（時々）間違える前提での運用設計

両者で最適解を探る前提で、柔軟に議論できる、
技術力のあるAIベンダーを見極めよう

Phase-1



Phase-1

AI導入効果アセスメント・パイロット検証

課題

- 目的と手段の行き違い
- ROIを無視したプロジェクト設計
- 解けないプロジェクト

- AI・ディープに偏った提案
- 実はルールで解決できる

- データの外の情報が実は重要

背景

<ユーザー側の課題>

- AIの理解不足 (最近少ない)
- 担当者のAI導入への過度のプレッシャー

<ベンダー側の課題>

- “AIしか” 知らず、技術提案が偏るベンチャー
- プログラマ・リサーチャー視点への偏り

<両者の課題>

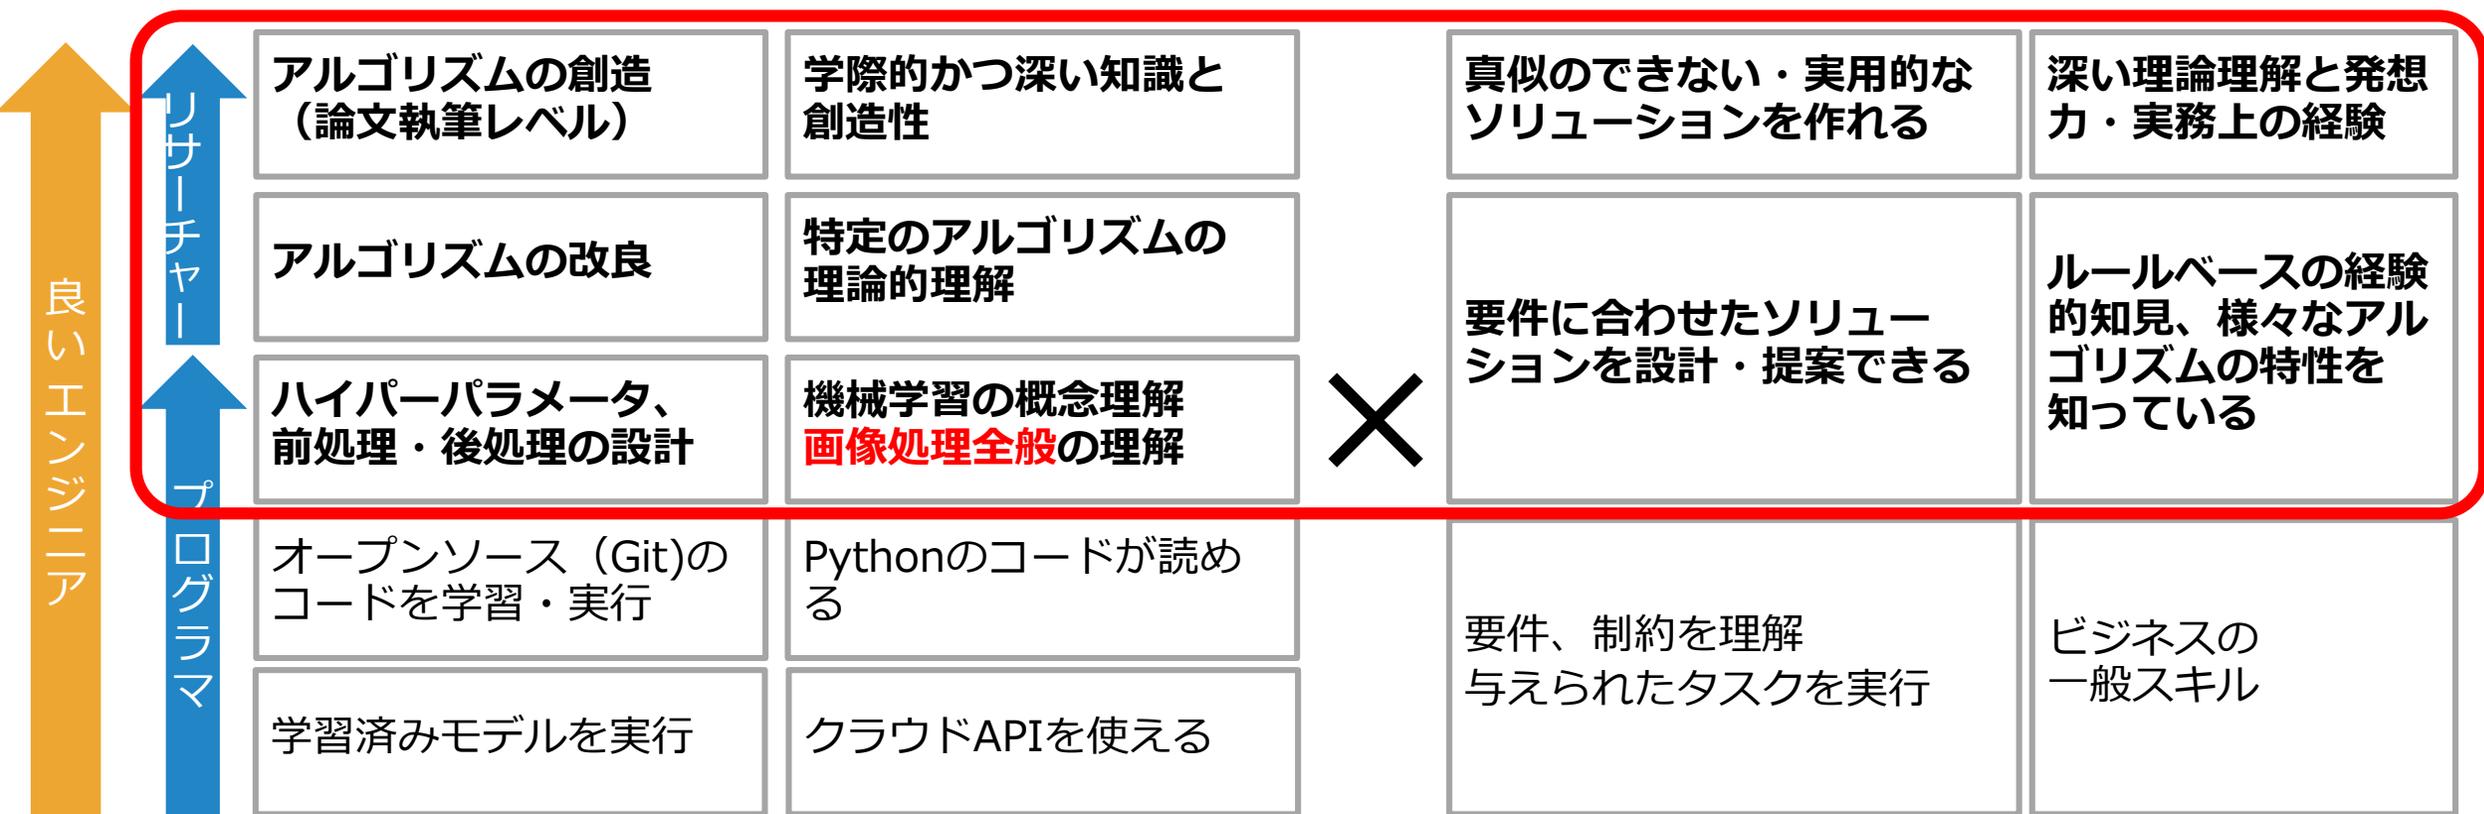
- そのデータ “だけ” 見て判断できるか チェック不足
- 試す前の検討に時間を使いすぎる

- **課題解決のためのAI導入**
 - 解決したい課題を明確化
 - AIありきではなくROIを議論
 - コスト削減だけでなく、市場創出のチャンスを議論すると発展的
- **AIを組み込んだソリューション**
 - ルールと解析手法の組合せ
 - 現在のディープラーニングは、目的特化と割り切る
 - 良いエンジニアのいるベンダーを探す
- **解ける課題なのか見極める**
 - データだけ見て判断できるかテスト (画像のシャッフルなど)
 - データとアルゴリズムの組合せを複数試す
 - 解けない可能性を認める

(参考) 良いエンジニア

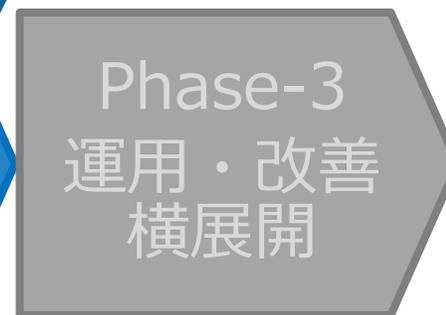
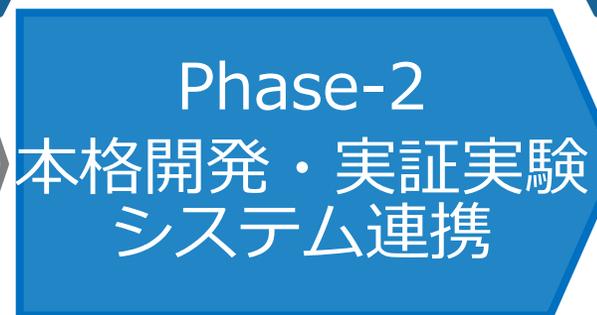
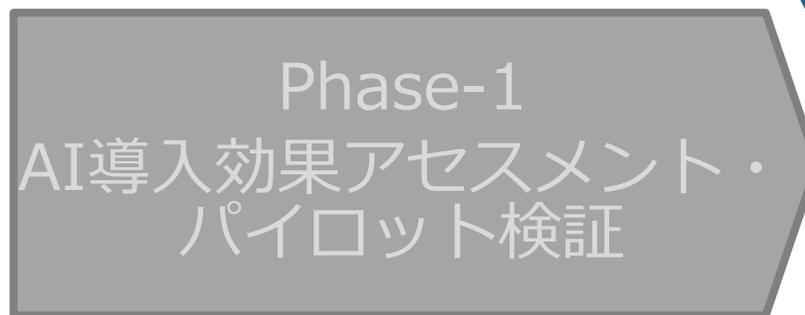
アルゴリズムを実装・考案する能力

社会課題を解決する
ソリューション提案・実現スキル



開発判断

導入判断



よく
ある
課題

- 目的と手段の行き違い
- ROIを無視したプロジェクト設計
- 解けないプロジェクト
- AI・ディープに偏った提案
- 実はルールで解決できる
- データの外の情報が実は重要

- アノテーション負担
- データ数の不足
- ラベル条件が変わる
- 何の指標をどう満たせば導入してよいのか？
- 精度が上がらない
- 精度 vs 速度

- 精度劣化
- 改善が難しい
- 誤認識による障害
- 似たタスクでもイチから開発

Phase-2

本格開発・実証実験システム連携

課題

- アノテーション負担が大きい
- ラベルの条件が変わる
- データ数の不足

- 精度が改善しない

- 何の指標をどう満たせば導入してよいのか？
- 精度 vs 速度

背景

<アノテーションの問題>

- アノテーションの定義は ビジネス要件に直結
- アノテーションの精度は、ディープの精度に直結

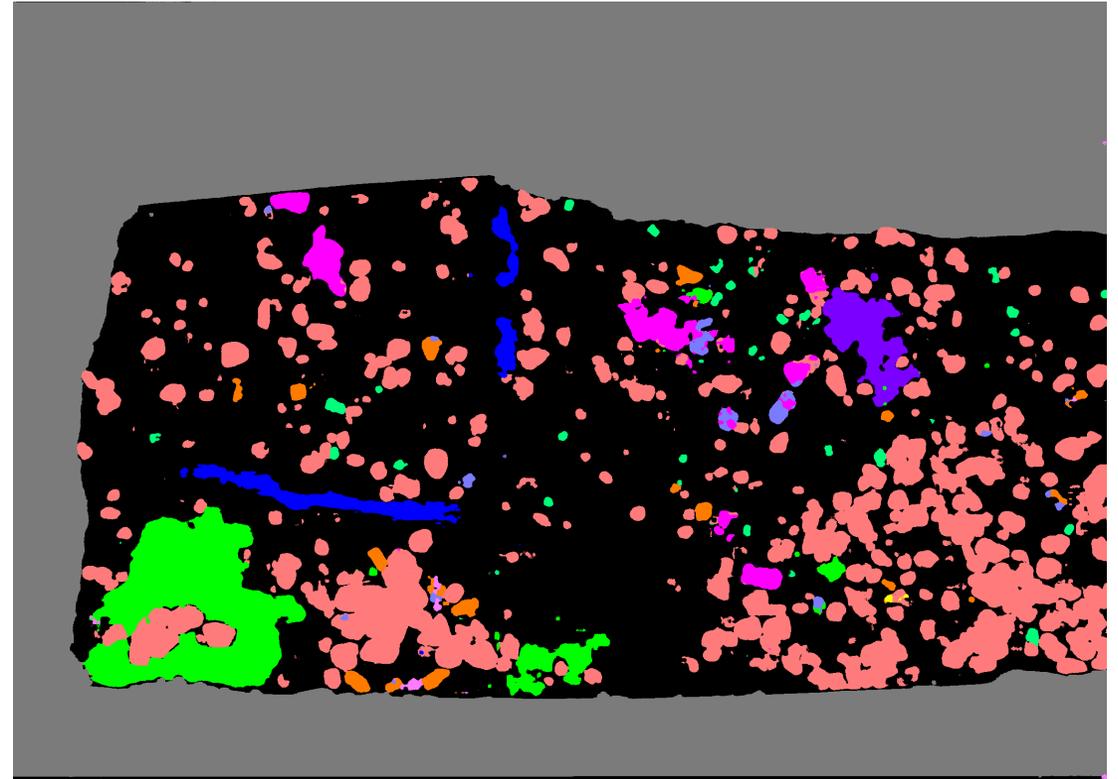
<データ量の問題>

- ビジネスレベルで1ピクセル毎に塗ると**1日数枚**のときも
- 論文や事例は 数千枚で学習した結果（時には数万枚）
- ベンダー側のスキル不足

<精度・導入判断の問題>

- システムに100%を求める誤謬
- 精度と速度はほぼ反比例の関係で両取りが困難

(参考) アノテーションとは





Andrej Karpathy, Tesla

「The data labelers are the programmers.」

柳原の認識：

「The data labelers decide project success」

2018.6.8 「Building the software 2.0 Stack」

※BaoBab社資料を参考

(状況)

自動運転車のディープラーニングが、
足だけ写った人を見逃して轢いてしまった。

(検証ポイント)

- 足だけ写った人を、**見つけたい対象**としてアノテーションしていたか？
- 足のケースを**どれだけ学習**したか？
- 精度評価について適切だったか？（この場合**Recall**重視）
- 足の映り方のバリエーションは適切だったか？
- 誤認識した場合に、クリティカルな事象を避ける仕組みはあったか？

※ブラックボックス議論は学習過程・結果の可読性であって大事な論点ではない

- **データの定義とビジネス要件のマッチ**

- ビジネス要件に沿ったアノテーションポリシーになっているか？
- アノテーションポリシーに沿って正確にラベルがつけられているか？
(Garbage IN , Garbage OUT)

- **運用時のデータと、学習データの違い**

- 学習データと、実運用データに違いはないか？
- 学習データに、実運用で起こりうるケースがどれだけ含まれているか？

- **ユーザー視点 手間の覚悟**
 - ベテラン作業者の協力と手間を予め見込む
 - 良いクラウドソースを活用する
 - ベテランも思い込みでラベル付けを間違える事も多い
- **ベンダー視点 少ないデータで精度を出す技術工夫**
 - 転移学習、ドメイン適応…
- **両者 一緒にビジネスを作る信頼関係**
 - ビジネス要件を出来る限り明確にする
 - 何回もアノテーション定義と学習を試して最適な定義を探る
 - 結果が出ないケースが出ることも覚悟

(再掲) 本格開発・実証実験フェーズの課題

Phase-2

本格開発・実証実験システム連携

課題

- アノテーション負担が大きい
- ラベルの条件が変わる
- データ数の不足

- 精度が改善しない

- 何の指標をどう満たせば導入してよいのか？
- 精度 vs 速度

背景

<アノテーションの問題>

- アノテーションの定義は ビジネス要件に直結
- アノテーションの精度は、ディープの精度に直結

<データ量の問題>

- ビジネスレベルで1ピクセル毎に塗ると**1日数枚**のときも
- 論文や事例は 数千枚で学習した結果 (時には数万枚)
- ベンダー側のスキル不足

<精度・導入判断の問題>

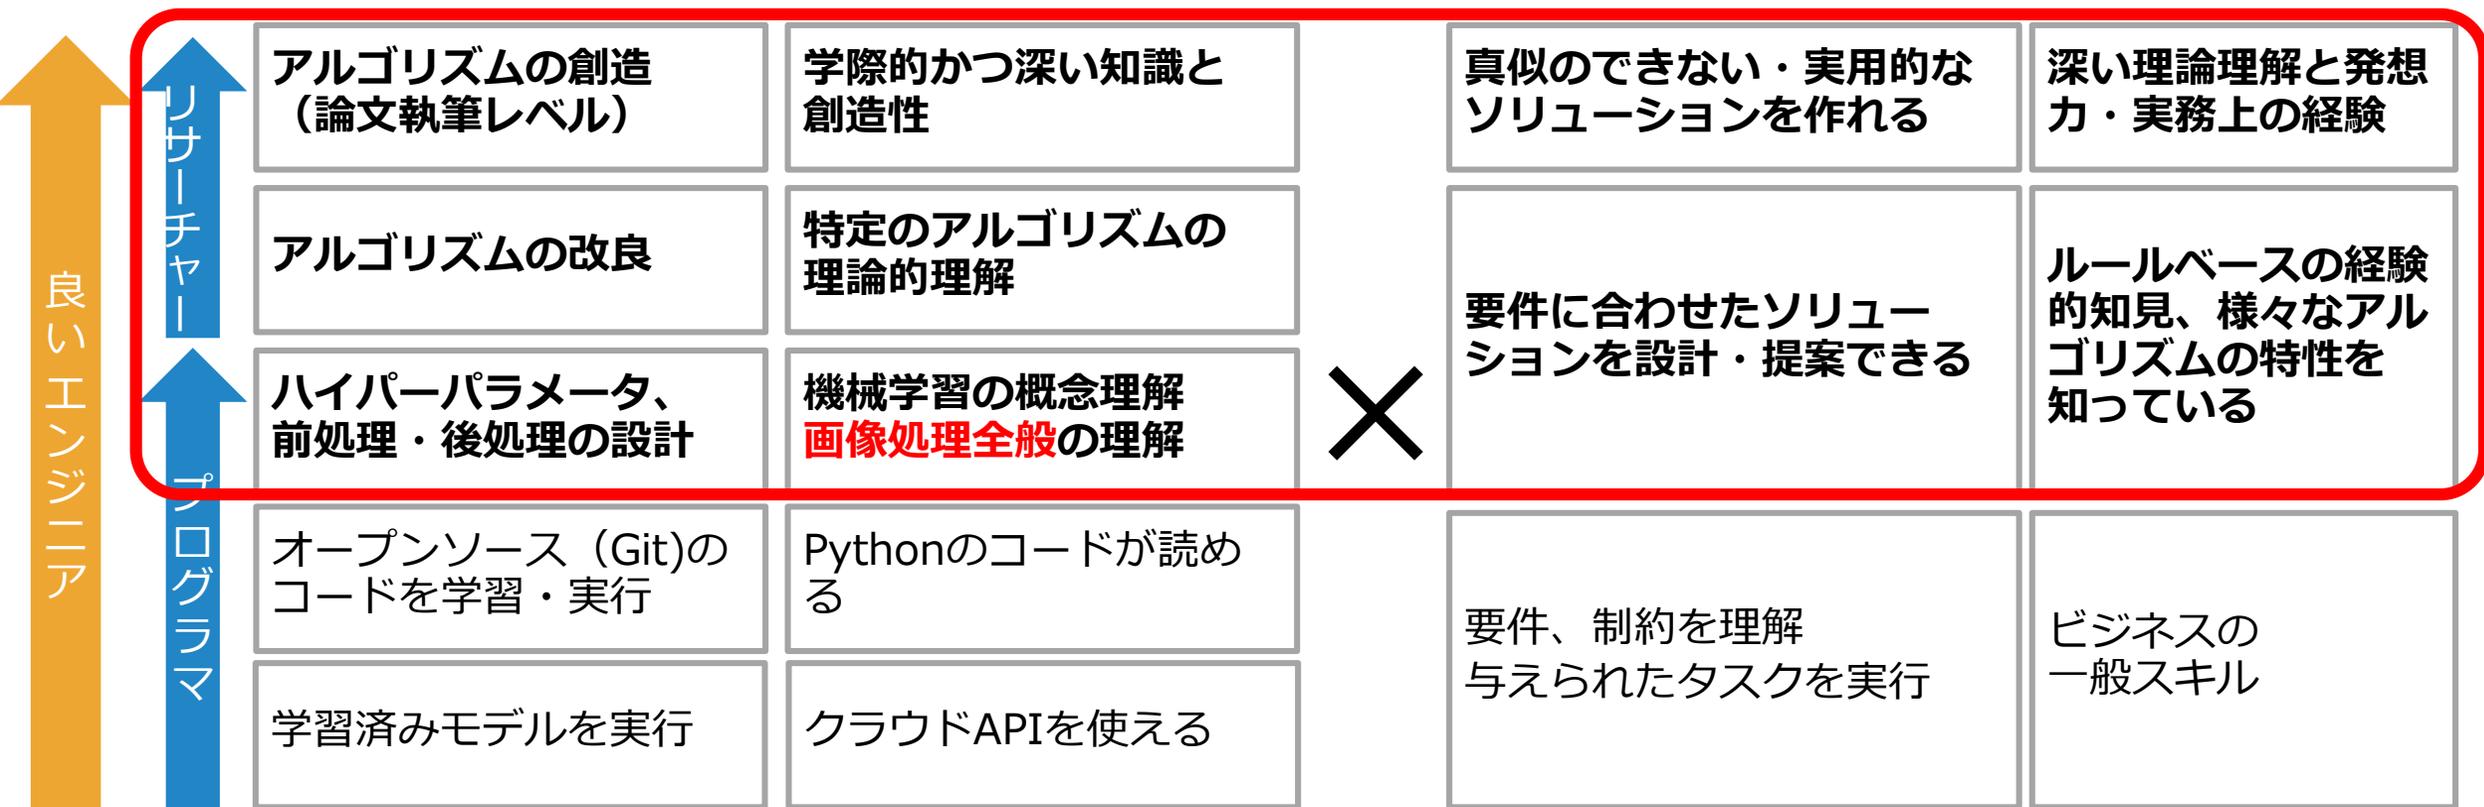
- システムに100%を求める誤謬
- 精度と速度はほぼ反比例の関係で両取りが困難

- **ラベルの優先度を定める**
 - 運用上重要なラベルについて、より多くデータを集める努力
 - 精度評価でも重視する項目（全部100点を狙うとつらい）
- **アルゴリズムの精度指標**
 - Recall（再現率）とPrecision（適合率）のどちらが適切か？
 - 定量評価・定性評価 の両軸できちんと見ているか？
- **導入判断の指標**
 - アルゴリズムの精度は一つの導入判断の指標
 - 人間を代替するタスクでは精度100%は求められない（人も間違える）
 - 実証実験での検証するポイントを明確にする。
（例：AIによる自動稼働時間がX時間を超える、など）

(参考) 精度を上げるための必須レベル

アルゴリズムを実装・考案する能力

社会課題を解決する
ソリューション提案・実現スキル



(参考) 異常検知の実用化に向けておきた課題

データ

- 完全な「良品」の定義が難しい
- 良品データ自体のばらつき (取得時期・振動 etc)
- データ数の不足 (例: 初回検証が数百枚程度)

不良データで精度も
あげる独自ロジック
(論文採択)

求められる精度

- 高解像度を維持する必要性
 - 低解像度で消える微細な傷
 - 全体を見て判断する必要
- 異常箇所をピクセル単位で表示
- 通常のGANだと、高解像度の学習が収束しない

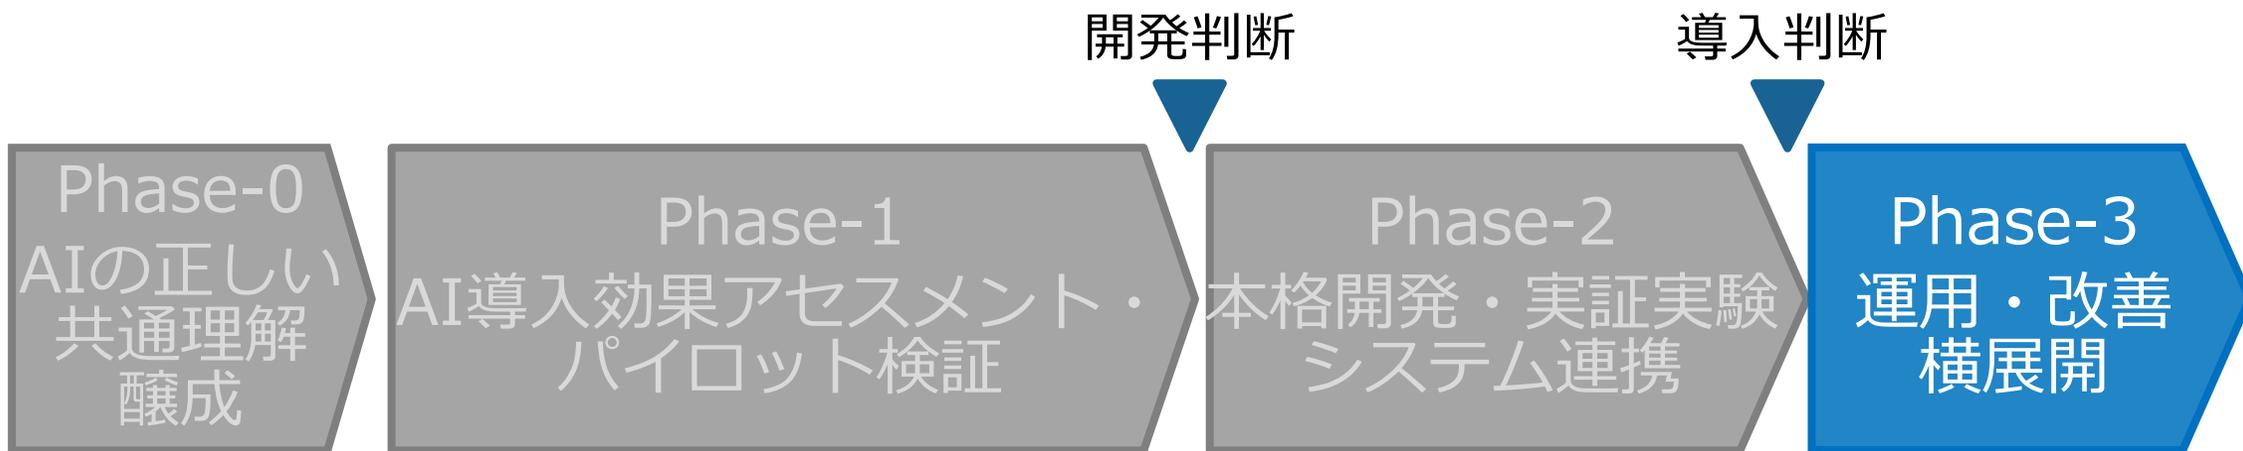
Anomaly Detection
GAN+
高解像度化の論文実装

処理速度

- PCサーバーでは学習に数週間かかってしまう
- 高解像度NNがメモリに乗り切らない

推論環境を複数検証
JETSON、クラウド、
オンプレ

P3 – 本格開発・実証実験フェーズ



よくある課題

- 目的と手段の行き違い
- ROIを無視したプロジェクト設計
- 解けないプロジェクト
- AI・ディープに偏った提案
- 実はルールで解決できる
- データの外の情報が実は重要

- アノテーション負担
- データ数の不足レベルの条件が変わる
- 何の指標をどう満たせば導入してよいのか？
- 精度が上がらない
- 精度 vs 速度

- 精度劣化
- 改善が難しい
- 誤認識による障害
- 似たタスクでもイチから開発

Phase-3 運用・改善・横展開

課題

- 精度劣化
- 改善が難しい
- 誤検出時の障害
- 似たタスクもイチから開発

背景

- センシング環境の揺らぎ（外乱、ほこり、固定 etc）
- ビジネス要件の変化（対象物の変化）
- ずっと使えるAIという間違った認識
- 精度が100%ありきの設計
- 目的特化のAIの弊害（ROIの意識の欠如）

- **環境をなるべく安定化させる努力**
 - 撮影条件が安定するカメラの設置位置やコンフィグの追求
- **解析対象の変化への汎用力**
 - 事前に起こりうる変化を予測し、データ増幅・加工による学習
 - 変化をいち早く検知する仕組みの導入
 - 継続した追加学習ポリシー
- **AIも人も（時々）間違える前提での設計**
 - 誤認識時のガードレール作り
- **プロジェクトスコープと協働体制**
 - 単発でROIを出すか、横展開含めて長期的なROIを目指すか

まとめ

AI開発アセスメント～開発・導入まで

開発判断

導入判断

Phase-0
AIの正しい
共通理解
醸成

Phase-1
AI導入効果アセスメント・
パイロット検証

Phase-2
本格開発・実証実験
システム連携

Phase-3
運用・改善
横展開

経営層・
関係者
向け講義

要望棚卸
AI/非AI
仕訳

AI導入
目的・
課題
の整理

データ
とAIの
組合せを
定義

AIパイ
ロット
検証

AI
開発・
導入計画
策定

AI
本開発

POC
周辺
システム
との
連携

導入
保守

改善
継続

アジャイルに行き来する柔軟性が重要

個々のフェーズで様々な課題

各フェーズで、ディープラーニング特有の様々な課題が発生

Phase-0
AIの正しい
共通理解
醸成

Phase-1
AI導入効果アセスメント・
パイロット検証

Phase-2
本格開発・実証実験
システム連携

Phase-3
運用・改善
横展開

よく
ある
課題

- 目的と手段の行き違い
- ROIを無視したプロジェクト設計
- 解けないプロジェクト
- AI・ディープに偏った提案
- 実はルールで解決できる
- データの外の情報が実は重要

- アノテーション負担
- データ数の不足
- ラベル条件が変わる
- 何の指標をどう満たせば導入してよいのか？
- 精度が上がらない
- 精度 vs 速度

- 精度劣化
- 改善が難しい
- 誤認識による障害
- 似たタスクでもイチから開発

- 目的にあった「ルール×AI」の適切なソリューション設計
- 良いアノテーションポリシーは プロジェクト成功の秘訣
- 導入判断に重要な指標を早めに見つける
- 解析対象の変化を見据えた汎用性
- AIも人も（時々）間違える前提での運用設計

両者で最適解を探る前提で、柔軟に議論できる、
技術力のあるAIベンダーを見極めよう



Ridge-i

AI・ディープラーニングによるインパクトを
実感できるまで追求します

ぜひお気軽にご連絡ください



<https://ridge-i.com>



contact@ridge-i.com