

モノづくりの現場で「使えるAI」を作るコツ

1. はじめに

近年、モノづくりの現場におけるAIの活用が急速に広がっている。AIを導入することで、品質管理、設備保全、生産計画、在庫管理などの様々な領域で効率化と最適化が実現出来ると期待されている。しかし、AI開発を途中で断念したり、開発したものの本番運用で使えていないなどの問題が発生し、全てがうまくいくわけではない。現場で価値を生み出し、業務を改善するには、「使えるAI」を作ることが不可欠である。

「使えるAI」とは、現場の課題を深く理解し、その解決が出来るAIのことを指す。単に技術的に優れているだけでなく、現場の人々に受け入れられ、日々の業務に自然と溶け込んでいくことが重要である。そのためには、現場の知見を取り入れながら、使いやすさと柔軟性を兼ね備えたAIシステムを設計・開発する必要がある。

本報では、Ridge-iのAIコンサルタントとして、モノづくりの現場で「使えるAI」を作るためのコツを紹介する。Ridge-iはAI開発の専門家集団として、数多くの企業のAI導入を支援している。製造業のお客様からは、AI開発をしたが上手くいかなかった、どのようにアプローチすれば良いかわからないという難易度の高い案件が多いのが特徴である。私自身、コンサルタントとしてRidge-iで約6年間で60案件に携わり、無事に導入出来たもの、検討段階で中断したもの、開発の途中で中断されたもの、ビジネスインパクトを生んだものなど、様々な経験をしている。本報ではAIの代表的な適用領域を説明し、AI導入時の課題と対応策を、具体的な事例を交えて解説し、AI導入の際に参考に出来る情報を提供する。

2. モノづくりの現場におけるAIの適用領域

モノづくりの現場では、AIを様々な領域で活用することが出来る。代表的な適用領域として、品質管理・検査、設備

保全・予知保全、設備運転などが挙げられる。Ridge-iの事例も含め、AIの適用内容を以下に記載する。

品質管理・検査の領域では、AIを用いて製品の外観検査や異常検知の省力化・自動化を行うことで、検査の作業量削減、検査品質の均一化による検査精度の向上、検査結果を基にした設計や工程の改善へのフィードバックが可能となる。例えば、ある製造業の検査工程において、AIによる画像解析を用いて不良箇所を自動的に検出することで、検査工程の作業量削減と検査品質の均一化を図っている。

設備保全・予知保全の領域では、AIを活用して設備の故障を予測し、計画的なメンテナンスを実施することが出来る。例えば、半導体製造工程において、設備の稼働状態を分析し、異常の兆候を早期に検知したいというニーズがあり、バルカー社とRidge-iにて振動データを用いた異常検知AIソリューションを開発し、提供を開始している。

設備運転の領域では、これまで作業員が行っていた設備運転にAIを導入することで、設備の自動運転を実現出来る。例えば、あるプラント企業において、クレーンの自動運転を行った事例がある。これにより、大幅な作業量削減を実現している。

以上のように、モノづくりの現場ではAIを多岐にわたる領域で活用することが出来る。各企業が自社の課題や目的に合わせてAIの適用領域を選択し、効果的に導入していくことが重要である。

3. 「使えるAI」を作るための課題と対応のポイント

モノづくりの現場で「使えるAI」を作るためには、AI導入時の課題を理解し、適切な対応を行う必要がある。まず、AIプロジェクトの全体像を示し、各工程における課題例と対応のポイントを解説する。

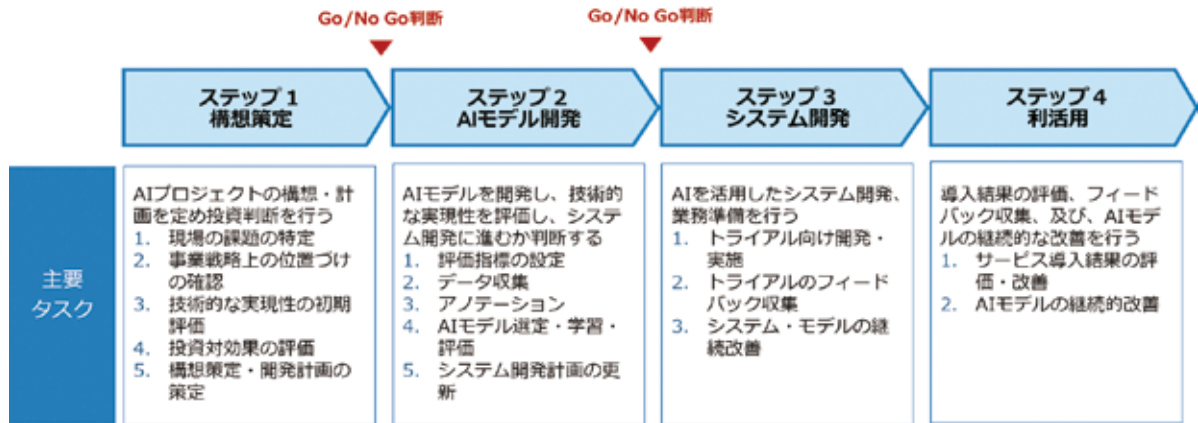


Figure1 AIプロジェクトの全体像

3-1) AIプロジェクトの全体像

AIプロジェクトは主に以下のステップで構成される。AIプロジェクトは一般的に投資額が大きく、また技術リスクも高いため、段階的に進めることで、適切な判断、投資リスクの低減を図る。

以降に、各工程における課題と対応のポイントを記載する。

3-2) 構想策定

現場業務の深い理解のもと解決すべき課題を特定し、事業戦略との整合を確認する。その上で技術的な実現性を評価し、投資対効果の有無を検証し、開発に進むか判断を行う。

■ 現場の課題理解と目的の明確化

課題：

現場の理解が不十分な状態では、課題の検討をした結果、現場の賛同を得られずプロジェクトが白紙となる。

対応のポイント：

現場にて、担当者のヒアリングや業務観察を通じて現状業務を理解し、課題を定量的・定性的に理解する。その上で、課題の対応方針、AI導入後の業務設計を行い、現場と方針の理解を合わせる。

■ 事業戦略上の位置づけの確認

課題：

現場のみの判断で進めた場合、効果がありそうであっても、事業戦略の実行の観点から優先度が落とされ予算やリソースがつかない。また、単一工程・業務の課題解決では、投資対効果に合わない。横展開も検討するが、他の現場は業務が違うため展開が困難。

対応のポイント：

現場の課題の事業戦略上の位置づけを明確にし、事

業戦略の観点から、その課題を優先的に対応すべきか判断する。事業戦略上、対応すべき課題となった場合に、検討範囲や着手順を全社の観点から設計する。

■ 技術的な実現性の初期評価

課題：

技術的な実現性が不明な状態で課題検討したが、技術的課題が発生しプロジェクトが中断する。

対応のポイント：

AIの技術特性を把握しているメンバーが、課題解決の技術的な実現可能性を初期段階で判定する。そのようなメンバーがいない場合は、AI開発企業にヒアリングするだけでも一定の難易度の把握が可能である。

AIプロジェクトは、主に以下の観点でチェックする。

Table1 技術的な実現性の初期評価

基準	観 点
データ取得の容易性	現状、作業員の判断で使用している情報源(動画像、テーブルデータ、振動、音など)は何か
	作業員が使っている情報を取得するためのセンシングデバイスは存在するか (例：時系列的な変化を見ているため動画である必要があり、カメラが必要)
	そのセンシングデバイスは現地に設置可能か
	データは取得可能か
	データ取得時の外乱は大きいのか
解析の容易性	対象物のバラエティは大きいのか (バラエティが大きい場合は難易度が上がる)
	AIに求める精度はどの程度か (AIは100%の精度は保証出来ない)
	AIに求める速度はどの程度か (AIの精度と速度はトレードオフ)
既存技術の流用可能性	既存技術(アルゴリズムやツール)の流用は可能か

■ 投資対効果の評価

課題：

投資対効果を試算した結果、投資対効果が出ず課題対応を中止する。

対応のポイント：

投資の効果について、現場課題解決の効果だけでなく、事業戦略への貢献も評価する。例えば外観検査の場合には、検査作業工数の削減だけでなく、事業戦略上、今後の販売量の増加を見据えた場合に、検査員の確保が困難になることが予想される場合は、AI導入は有力な対策となる。

また、狙う効果の金額についても、初期段階で簡易的に試算を行い、検討メンバーにて認識を合わせる。

投資額について、大きく間違えない程度で試算を行う。

- 初期投資：データ準備、AIモデル開発、システム開発、設備投資
- 運用費用：システム保守、AIモデルの維持向上

AIは作って終わりではなく、運用時に継続的な改善が必要なため、AIモデルの維持向上も試算に含める。

3-3) AIモデル開発

業務課題に即したAIモデルの評価指標を設計し、データ収集・準備後にAIモデル開発を行い、実用性を評価する。その上で、現場導入を見据えたシステム開発に進むか判断する。

■ 適切な評価指標の設定

課題：

精度のみを評価指標としAIモデル開発を行ったが、速度が遅く現場導入を断念。現場導入をしたが、外部環境の変化により開発時の精度が出ず、本格利用に進まない。

対応のポイント：

業務フローを設計し、その業務フローの実現可能性を評価するための評価指標を設定する。一般的には、AIモデルは精度、速度、汎化性、説明性の観点から評価指標を設定する。

Table2 適切な評価指標の設定

対 象	評価指標設計のポイント
精 度	現場導入に求められる精度を測定するための評価指標と目標値を定義する。 外観検査の場合には、評価指標としては、異常の検出率（異常を正しく検出出来るか）、正常の判定率（正常を間違えて異常と判定しないか）の2軸から判断することが多い。 精度は100%を前提とせず、100%でなくても使える業務フローを設計し、その業務フローで必要とされる精度を目標値とする。 また、精度の目標値も一律の目標値とせず、業務観点で優先度をつける。外観検査で異物を検出する場合には、検出したい異物の優先度をつける。
速 度	業務フローを設計し、その業務を成り立たせるために必要な解析速度を定義する。 解析速度は速ければ速い方が良いが、精度と速度はトレードオフの関係があるため、現実的な速度を定義する。
汎化性	解析したい対象をカテゴリ化し、重要なカテゴリを複数、もしくは、違いが大きいカテゴリを評価対象とする。 外観検査の場合には、対象製品をカテゴリ化し、2つのカテゴリからなる場合は、その2つのカテゴリに含まれる製品で評価する。 AIはデータを基に学習するため、学習が不十分なデータの場合には精度が低下する可能性がある。評価指標として汎化性を含めることで、データ準備漏れを防ぐ。
説明性	AIモデルは、何を基に判断しているか不明確になりブラックボックス化しやすい。 外観検査の場合は、AIモデルが画像のどこを基に異常、正常を判断しているかヒートマップで見える化し、正しく判断しているか確認を行う。

■ AIの技術特性を踏まえたデータ収集

課題：

少量のデータ、実環境のばらつきを踏まえたデータを基にAIモデルを開発した結果、期待する性能が出ない。

対応のポイント：

実運用環境のバリエーションを踏まえたデータと最低限のデータを収集する。

以下の観点でデータ収集を行う。

Table3 AIの技術特性を踏まえたデータ収集

対 象	データ収集のポイント
データ取得方法	なるべく本番と同様な環境で、同一のセンサーでデータ取得を行う。 本番と違う環境や方法でデータを取得した場合に、検証結果の妥当性が下がり判断が困難となる。
データのバリエーション	本番と同様なデータのバラエティを確保する。 画像を使った外観検査の場合、主に以下の観点でバラエティを確保する。 対象物のサイズ、色、形、角度、表面（テクスチャ）の違い。 外乱による明るさ、影の違い。
データ量	上記のデータのバラエティを網羅したデータを取得する。 データ量は様々な条件によって変わるが、画像の場合は、最低限1クラスあたり100枚以上用意する。

■ 現場の知見を踏まえたデータのアノテーション(ラベル付け)

課題：

AI 開発者の理解に基づきアノテーションを行う。その結果、本来の業務と違う定義でアノテーションを行ってしまい、業務上の定義と差異が生じ、間違った AI 学習に時間を費やす。

対応のポイント：

現場の熟練技術者の判断基準を確認し、アノテーション設計書を作成し、それにアノテーションを行う。アノテーションの結果は担当者だけでなく、第三者がアノテーション設計通り実施されているかダブルチェックする。曖昧な点は積極的に熟練技術者に確認を行う。アノテーションが AI モデルの性能の 50% を左右するといっても過言ではないため、重要な工程である。

■ 評価軸に基づく適切な AI モデルの選定

課題：

決め打ちで AI モデルを選定したが、期待性能、データ量の制限などの理由により狙った AI モデルの開発が出来ない。

対応のポイント：

本番導入を見据えた評価軸を設計し、その評価軸を満たす可能性の高い AI モデルを選定する。

- 評価指標(精度、速度、汎化性、説明性)
- 収集出来るデータ量・質・ばらつき
- 運用時の手間・コスト制限

難易度の高い課題の場合に 1 つの AI モデルにて解決出来ないことが多く、複数の AI モデルやアルゴリズムの組み合わせになることが多い。その場合であってもまずは評価軸を基に設計の正しさを評価する。

■ 実験計画に基づく学習・評価

課題：

AI モデルを 1 回作成し、期待する性能が出ないため開発を中止する。何度も AI モデルの開発・評価を繰り返し、解けない課題に多くの投資をしてしまう。

対応のポイント：

AI モデルの学習・評価を行き当たりばったりで行わない。まず実験計画を立て、実験の結果を評価し、その結果を基に実験計画を定めるサイクルを回す。また、一定の期間を定めて、その時点での課題と対応案の実現性を評価し、継続するかを判断する。Ridge-i では、基本的には 3 か月で判断を行うようにしている。

3-4) システム開発

■ 段階的な導入による改善サイクル

課題：

最初から最終形のシステムを開発し現場導入するが、期待する結果が出ない。また、現場から多くの改善要望をもらい、それに対応した結果、システム開発費用が予算を超過する。

対応のポイント：

段階的に現場導入を行い、現場での評価・フィードバックを得ながら開発を進める。Ridge-i では、一般的にまず現場で使える最低限の機能に絞り開発を行い、トライアルを実施して現場のフィードバックを得る。そのフィードバックを基に改善サイクルを回すことで、現場の要望に沿ったシステム開発を行っている。

■ 現場の業務・制限を踏まえたシステム設計

課題：

AI モデル開発を行い、そのあとシステム設計を初めて行う。その結果、想定外の課題が発生する。

対応のポイント：

構想策定段階で業務フローを作成し、AI、ハードウェア、ソフトウェア、制限事項の要件を定義し、それに沿った AI モデル開発を行う。AI モデル開発が終了した段階で、AI、ハードウェア、ソフトウェアの設計の見直しを行う。このように最初の段階から現場の業務や制限を踏まえたシステム設計を行う。

■ 現場で使いやすいユーザーインターフェース

課題：

現場の業務・要望を確認せずにユーザーインターフェースを開発し、現場導入時に多くの問題の指摘を受け再開発となる。

対応のポイント：

設計段階で画面モックアップを作成し、現場担当者からフィードバックを得る工夫をする。AI 導入は、現場の業務の変更を伴うことが多いため、AI を導入したとしても、業務がスムーズに行え、業務負荷が少ないものとする。

3-5) 利活用

■ 継続的な改善を見据えた運用体制の整備

課題：

AIモデルの改善を見据えた体制や仕組みがなく、徐々にAIの精度が低下し、最終的にAIモデルの性能が悪化し使えなくなる。

対応のポイント：

AIモデルの性能のモニタリングを行い、性能の低下が発生した場合はAIモデルの再学習を行う。このサイクルを回せるようにシステム開発を行い、運用準備をしておく。

■ AIに過度に依存せず、AIは現場作業員の支援と位置付ける

課題：

AI導入により現場スタッフがゼロになる前提を置く。AIは間違える場合もあり、想定通りにならない。

対応のポイント：

AIは100%ではないことを前提にし、現場作業員の支援ツールとして位置付ける。AIの判断の信頼度が低い場合、AIの判断は安全サイドに倒すなどして、無理のない業務設計をする。

4. おわりに

モノづくりの現場で「使えるAI」を作るためには、現場の知見とAI技術を融合させることが重要である。AIプロジェクトを成功に導くには、現場の課題や業務を深く理解し、それに基づいて適切な評価指標やデータ収集方法を設計することが不可欠である。また、現場の熟練技術者の知見を取り入れながら、AIモデルの開発とシステム設計を進めることで、実用性の高いソリューションを実現出来る。

ただし、AIの導入は一度で完了するものではない。継続的な改善と柔軟な運用体制を整備することが、長期的な成功につながる。AIモデルの性能をモニタリングし、必要に応じて再学習を行うサイクルを回すことで、変化する現場の要求に適応していくことが出来る。また、AIを現場作業員の支援ツールと位置付け、過度な依存を避けることも重要である。

「使えるAI」を作るには、現場とAIのエキスパートが密に連携し、継続的に改善を重ねていく努力が欠かせない。本報で紹介したポイントを参考に、各企業がモノづくりの現場にAIを効果的に導入し、生産性向上と競争力強化を実現することに期待したい。



横山 慶一
株式会社Ridge-i
コンサルティング部