AIを活用した売上予測・需要予測入門

経営と現場の判断材料を増やすための、実務起点の導入ガイド
— 小さく始めて効果を測る、予測活用の進め方 —

Start Challenge Consulting co., ltd.

対象：経営者／営業企画／マーケティング／在庫管理・SCM部門　発行日：2026年8月

Strictly Confidential — 本資料の全部または一部の無断転載・二次利用を禁じます。

Start Challenge
Consulting co., ltd.
挑む力が、世界を照らす

はじめに

売上・需要予測は「未来を当てる」ための取り組みではなく、在庫・人員・予算という有限な経営資源を、需要が発生する前に配分するための判断材料を用意する仕組みである。

売上・需要予測が経営判断に必要な理由

01 意思決定の多くが「需要が確定する前」に必要

発注・生産・要員配置・広告投資は、実績が判明する前に決めなければならない。予測は、その前提条件を数値で共有するための言語となる。

02 誤差がそのままコストと機会損失になる

過大予測は在庫過多・廃棄・値引きを生み、過小予測は欠品と販売機会の逸失を生む。予測精度の改善は、双方の損失を同時に圧縮する。

03 判断の根拠を組織で再現・検証できる

同じデータと同じ手順から予測値を導けば、結果の振り返りと改善が可能になる。属人的な勘とは異なり、組織の資産として蓄積できる。

本資料の対象読者と、想定する関心事

経営者・事業責任者	投資判断の前に、AI予測で何がどこまで変わるのかを把握したい
営業企画・経営企画	目標設定・予算策定・着地見込みの精度と、更新の速さを高めたい
マーケティング	販促・価格の効果を織り込んだ需要の見通しを、計画に反映したい
在庫管理・SCM・生産	発注量・生産計画を決めるうえで、欠品と過剰在庫の両方を減らしたい
情報システム・DX推進	必要なデータ・体制・運用フローを具体化し、実現可能性を見極めたい

本資料の読み進め方

第1〜2章で予測の前提と仕組みを整理し、第3〜4章で活用場面と手法・システム構成を示す。第5〜6章では、データ品質・導入ステップ・評価方法・失敗要因という「実行フェーズの論点」を扱う。

注記　事実：意思決定は実績確定前に行われる業務が多い／解釈：予測は資源配分の判断材料である／提案：投資判断の前に対象業務と評価範囲を先に定義する

売上予測・需要予測とは

売上予測は「金額」で経営計画を支え、需要予測は「数量」で現場のオペレーションを支える。両者は同じ実績データから異なる粒度・単位で導かれるため、どちらを目的とするかで必要なデータと精度要件が変わる。

観点	売上予測（Sales Forecast）	需要予測（Demand Forecast）
主な単位	金額（売上高・粗利）	数量（販売数・出荷数・来店客数）
主な目的	計画の妥当性確認と着地見込みの把握、資源投下の意思決定	供給量の決定（発注・生産・配送・要員手配）
粒度	全社／事業／部門／担当・月次・四半期が中心	商品（SKU）／店舗・拠点・日次〜週次が中心
主な利用部門	経営企画・営業企画・財務	在庫管理・SCM・生産・店舗運営
外れたときの影響の出方	**計画と実績の乖離**：期中の方針転換、投資判断の遅れ	**在庫の過不足**：欠品による機会損失、過剰在庫と廃棄

予算計画・在庫・人員配置との関係 — 予測値は、3つの計画に同時に接続する

予算計画

売上予測が予算の前提となり、販促費・人件費などの投下枠を決める。着地見込みの更新に応じて期中の配分も見直す。

在庫・調達

需要予測が発注量・安全在庫の基準となる。リードタイムを考慮し、予測期間は補充までの期間以上に設定する必要がある。

人員配置

来店客数・出荷量の見通しがシフトや工程要員の計画に反映される。日次・時間帯の粒度が求められる領域である。

注記　事実：売上予測は金額、需要予測は数量を対象とする／解釈：目的が異なるため必要な粒度と精度要件も異なる／提案：着手時に「金額か数量か」「どの粒度か」を先に確定する

従来の予測方法が抱える課題

担当者の経験に依存した予測は、根拠が可視化されないまま更新が遅れ、結果として在庫の過不足と機会損失が経営数値に現れる。課題は精度そのものではなく、「再現性」と「更新速度」の欠如にある。

課題1依担当者の経験への依存

発生している事象

予測値の根拠が個人の記憶と感覚に置かれ、なぜその数値なのかを第三者が説明できない。

直接原因

判断に使った条件（前年比・販促・天候など）が記録されず、手順が標準化されていない。

構造的原因

予測の当否が振り返られず、改善が個人の学習にとどまり組織に蓄積されない。

課題2依表計算ソフト集計の限界

発生している事象

対象が商品×店舗×日次に細分化されるほど、集計作業量が急増し扱いきれなくなる。

直接原因

転記と手作業の関数修正が前提となり、ファイルの分岐・数式の破損・入力誤りが起きやすい。

構造的原因

複数要因を同時に考慮する処理が不得手で、扱える説明変数が実質的に限られる。

課題3依予測更新の遅れ

発生している事象

月次更新が中心となり、直近の実績や環境変化が判断に反映されるまで時間差が生じる。

直接原因

データ収集から集計・確認・共有までが人手で連鎖し、1サイクルの所要時間が長い。

構造的原因

更新頻度が業務の締めスケジュールに固定され、必要なタイミングで再計算できない。

業務・経営への影響

在庫過多・値引き・廃棄によって粗利が目減りする

欠品による販売機会の逸失と顧客満足の低下が発生する

計画と実績の乖離が大きく、期中の是正判断が後手に回る

予測業務が特定担当者に集中し、異動・退職が業務継続リスクになる

注記　事実：構成案に示された3課題（経験依存・表計算の限界・更新遅延）を整理／解釈：本質は精度不足ではなく再現性と更新速度の不足／仮説：更新頻度の向上が先行して効果を生む（仮）

AI予測の基本的な仕組み

AI予測は、過去データに含まれる規則性を「モデル」として抽出し、同じ規則を将来の条件に当てはめて数値を出力する仕組みである。したがって予測の質は、モデルの新しさよりも入力データの質と条件設定に規定される。

① 過去データの収集

売上実績・在庫・価格・販促などを、同じ粒度（期間・商品・拠点）に揃えて集める。

② 前処理・特徴量作成

欠損・重複・表記揺れを補正し、曜日・季節・イベントなどを説明変数として整える。

③ 学習（パターン抽出）

「どの条件のとき、どれだけ売れたか」の関係を、誤差が小さくなるように数式化する。

④ 検証・モデル確定

学習に使わない期間で誤差を測り、実運用に耐える精度かどうかを確認する。

⑤ 予測値の出力・活用

将来の条件を入力して数値を算出し、発注・計画・目標などの業務判断に接続する。

※ ③④は「学習フェーズ」（過去を材料にモデルをつくる）、⑤は「推論フェーズ」（つくったモデルで将来値を出す）。実績が積み上がるたびに学習をやり直すことで、モデルは環境変化に追随する。

仕組みから導かれる、押さえておくべき3つの前提

過去に例のない事象は予測できない

モデルは過去データの規則性を根拠にする。新商品の初動、制度変更、突発的な需要急変などは、学習材料が存在しないため人の判断で補う必要がある。

予測値は点ではなく幅として扱う

出力は「最もあり得る一点」に過ぎない。上振れ・下振れの幅を併せて把握し、安全在庫や意思決定の余裕幅に反映させることが実務上重要となる。

入力データの質が精度の上限を決める

同じモデルでも、粒度が粗い・欠損が多い・記録ルールが揃わないデータでは精度は上がらない。改善の起点は多くの場合データ側にある。

注記　事実：AI予測は学習フェーズと推論フェーズから成る／解釈：精度の上限は入力データの質と粒度に規定される／提案：モデル選定より先にデータ整備の範囲を決める

AIで予測精度を高められる理由

精度が向上する要因は「賢いアルゴリズム」ではなく、人手では処理しきれない量のデータを、複数要因の組み合わせとして同時に評価できる点にある。従来手法との差は、扱える情報量と更新頻度の差に還元される。

精度が高まる要因	従来の予測方法（As-Is）	AIを用いた予測（To-Be）	業務上の意味
① 大量データの処理 Volume	主要商品・主要拠点に絞った集計。全SKU×全店舗を日次で見ることは作業量の制約から困難。	**全SKU×全拠点×日次**を一括で処理。長期の履歴も一度に学習対象にできる。	売れ筋以外の商品も対象化でき、在庫が滞留しやすい裾野の管理が可能になる。
② 複数要因の同時分析 Variables	前年同月比に、担当者が数個の要因を加減算で補正。要因の相互作用は考慮しにくい。	価格・販促・天候・曜日・競合などを**同時に評価**し、組み合わせ効果も反映する。	「値下げと週末が重なった場合」のような複合条件の見通しが得られる。
③ 季節性・トレンドの把握 Pattern	季節指数を手作業で設定・更新。商品ごとに異なる周期性を個別に持たせるのは負荷が高い。	年周期・週周期・長期トレンドを**データから自動的に分離**し、商品ごとに個別化する。	季節商品の立ち上がり・終息の時期判断が、経験値に依存せず標準化される。
④ 更新の自動化 Frequency	月次の締め作業に合わせた更新が中心で、直近の変化の反映に時間差が生じる。	実績が入るたびに**日次・週次で再計算**でき、環境変化への追随が早まる。	期中の是正判断が早期化し、修正のための打ち手の選択肢が広がる。

留意点 —「AIを使えば必ず精度が上がる」わけではない

需要が安定した商品では、移動平均などの簡便な手法でも十分な精度が得られる場合がある。AIの効果が大きいのは、要因が多く・変動が大きく・対象点数が多い領域である。まずは自社のどの領域が該当するかを見極めることが、投資判断の起点となる。

注記　事実：AIは大量データ・複数要因・周期性の同時処理が可能／解釈：従来手法との差は扱える情報量と更新頻度の差である／仮説：変動が小さい商品群では改善幅は限定的（仮）

予測に利用する主なデータ

必須は「売上実績」と「商品マスタ」の2種であり、他は精度向上のための追加要因である。まず社内で即座に揃うデータ範囲で着手し、効果を確認しながら外部データへ拡張する順序が現実的である。

第1層　必須データ — これがなければ予測は成立しない

売上・出荷実績

日付・商品・拠点・数量・金額。予測対象そのものの履歴であり、最低でも1年、季節性を捉えるには2年以上が望ましい。

主な取得元：POS／販売管理／基幹システム

商品マスタ

商品コード・カテゴリ・定価・発売日・廃番日。同一商品を一意に識別できることが、履歴の連続性を担保する前提となる。

主な取得元：商品管理システム／マスタ台帳

第2層　精度向上に寄与する社内データ — 需要が動いた「理由」を説明する

価格	販売価格・値引率・改定履歴。需要量に対する影響が大きい要因	**顧客**	会員区分・購買頻度・取引先別実績。法人取引では特に重要
販促	チラシ・クーポン・広告出稿・棚割変更の実施期間と対象商品	**在庫**	在庫数・欠品履歴。欠品期間の売上減を需要減と誤認しないために必要
曜日・季節	曜日・祝日・連休・月初月末・イベント日。カレンダーから生成可能	**営業活動**	商談件数・進捗段階・受注確度。売上予測の先行指標として機能する

第3層　外部データ — 効果は大きいが、取得・維持のコストを見極めて選択する

天候・気象

気温・降水・天候予報。飲食・小売・季節商材で影響が顕著に出やすい

外部指標・市況

景況指数・原材料価格・為替・業界統計。中長期の水準変化の説明に用いる

地域・立地・イベント

人流・近隣イベント・競合出店。店舗別予測の差異要因として有効

注記　事実：予測の必須入力は実績履歴と商品マスタである／解釈：他データは需要変動の理由を説明する補助要因／提案：第1層＋第2層の社内データで着手し、第3層は効果検証後に追加する

売上予測の活用事例

売上予測の価値は「目標数値をつくること」ではなく、目標と着地見込みの差を早期に検知し、期中に打ち手を選び直せる状態をつくることにある。予測は計画の代替ではなく、計画の監視装置として機能する。

① 営業目標の設定

従来のやり方

前年実績に一律の成長率を掛け、部門・担当へ按分する

AI予測を用いた場合

担当領域ごとの需要見通しを踏まえ、達成可能性を検証した水準で目標を設定できる

主な効果

目標の納得性が高まり、未達要因の切り分けが容易になる

② 予算策定

従来のやり方

積み上げた希望値をもとに費用枠を決め、期中の変化には追随しづらい

AI予測を用いた場合

複数シナリオ（保守・標準・積極）の売上見通しに応じた費用配分を事前に用意できる

主な効果

前提が崩れた際の再配分判断を、あらかじめ設計できる

③ 店舗別・商品別売上予測

従来のやり方

全社計画を店舗規模などで按分し、店舗ごとの特性は反映されにくい

AI予測を用いた場合

立地・客層・曜日構成の違いを織り込み、店舗×商品単位で見通しを算出する

主な効果

品揃え・シフト・販促の店舗別最適化につながる

④ 着地見込みの把握

従来のやり方

月末に近づいてから見込みが判明し、対策の時間が確保できない

AI予測を用いた場合

日次の実績を織り込み、期末着地の見通しを継続的に更新し続ける

主な効果

未達の兆候を早期に把握し、打ち手の選択肢が残る段階で動ける

共通する要点 — 売上予測は「目標」ではなく「見通し」であり、両者を混同しないことが運用の前提となる

目標（コミットメント）

組織として達成を約束する意思の表明。施策や投資の効果を織り込んだ、上方への意図を含む数値。

見通し（フォーキャスト）

現在の条件が続いた場合に到達する水準の推定。意図を含まず、目標との差分が打ち手の必要量を示す。

注記　事実：売上予測は目標設定・予算策定・店舗商品別予測・着地見込みに用いられる／解釈：価値は差分の早期検知にある／提案：目標と見通しを別指標として並列管理する

需要予測の活用事例

需要予測の効果は、予測値そのものではなく「発注量・生産量という意思決定への接続」によって発生する。欠品削減と在庫削減は相反しやすいが、予測の幅を前提に安全在庫を設計することで同時追求が可能になる。

需要予測が接続する4つの業務判断

① 在庫最適化

商品別に需要の水準と変動幅を把握し、安全在庫を個別に設定する。全商品一律の在庫日数基準から、変動の大きさに応じた基準へ移行できる。

主な指標：在庫回転日数／在庫金額／滞留在庫比率

② 発注量の決定

補充リードタイム分の需要見通しから必要量を算出する。担当者ごとに異なっていた発注判断を、共通ロジックとして標準化できる。

主な指標：発注精度／発注作業時間／緊急発注件数

③ 欠品・廃棄の削減

下振れ側の誤差が欠品を、上振れ側の誤差が廃棄を生む。誤差の方向を分けて評価し、商品特性に応じてどちらを優先するか決める。

主な指標：欠品率／廃棄率／値引き販売比率

④ 生産計画

中期の需要見通しから生産量・原材料調達・要員計画を組む。段取り替えの回数や稼働の平準化にも影響する領域である。

主な指標：計画変更回数／稼働率／原材料在庫

予測誤差は「方向」で影響が異なる — 単一の精度指標だけでは業務判断を最適化できない

誤差の方向	現場で起きること	経営数値への影響	優先して抑えるべき商品
予測が実績を下回った（過小予測）	欠品・棚落ち、緊急発注、代替品への振替対応	売上機会の逸失、顧客離れ、緊急調達の追加コスト	売れ筋・代替困難品・長期保存が可能な商品
予測が実績を上回った（過大予測）	在庫滞留、保管スペース逼迫、値引き処理、廃棄	粗利の目減り、キャッシュフローの悪化、廃棄コスト	生鮮・消費期限品・季節限定品・単価の高い商品

注記　事実：需要予測は在庫最適化・発注・欠品廃棄削減・生産計画に用いられる／解釈：誤差の方向により損失の性質が異なる／提案：商品特性別に許容する誤差方向を先に定義する

業種別の活用イメージ

同じAI予測でも、業種によって「予測すべき対象」「必要な粒度」「効果が現れる指標」が異なる。自社がどの型に近いかを見極めることが、対象業務の選定と効果測定の設計につながる。

小売・EC

予測対象
店舗×SKU×日次の販売数、EC商品別の受注数

主な用途
自動発注、棚割・品揃えの調整、セール企画の効果見込み

特徴的な要因
価格・販促の影響が大きく、曜日・天候の効果も明確に現れる

効果が出る指標
欠品率／廃棄率／発注作業時間

製造

予測対象
製品別出荷数、得意先別の受注量（中期）

主な用途
生産計画、原材料調達、工程要員計画、在庫水準の設定

特徴的な要因
リードタイムが長く、予測期間も長期化。市況・受注情報の比重が高い

効果が出る指標
計画変更回数／在庫金額／稼働率

飲食

予測対象
店舗別・時間帯別の来店客数、メニュー別の出数

主な用途
食材発注、仕込み量の決定、シフト作成

特徴的な要因
天候・気温・近隣イベントの影響が強く、日次より細かい粒度が必要

効果が出る指標
食材廃棄率／人件費率／機会損失

卸売

予測対象
得意先×商品別の出荷量、拠点別の在庫必要量

主な用途
仕入計画、拠点間の在庫配置、配送計画

特徴的な要因
取引先の販促計画に需要が左右され、点数が非常に多い

効果が出る指標
在庫回転日数／欠品率／緊急配送件数

サービス業

予測対象
予約数・利用件数・問い合わせ件数、契約更新の見込み

主な用途
要員配置、拠点キャパシティ計画、解約予兆への対応

特徴的な要因
在庫を持たない代わりに、供給量＝人員の制約が効果を左右する

効果が出る指標
稼働率／待ち時間／人員過不足時間

業種を横断する共通点

いずれの業種でも、効果が現れるのは「予測値が特定の業務判断に直結している」場合に限られる。逆に、予測結果を参考情報としてのみ配信する運用では、精度が高くても業務指標は改善しない。

注記　事実：業種により予測対象・粒度・評価指標が異なる／解釈：効果は業務判断への接続度に依存する／提案：自社に近い型を選び、改善対象の指標を1つ定めてから着手する

代表的な予測手法

手法は「高度なものが常に優れる」わけではなく、対象データの性質と説明可能性の要件で選ぶ。実務では簡便な手法を基準値（ベースライン）とし、それを上回るかどうかで機械学習の採用を判断する。

手法	考え方	適した場面	留意点	説明可能性
移動平均 Moving Average	直近数期間の実績を平均し、次期の水準とみなす	需要が安定した定番商品、比較用のベースライン	季節変動や急な水準変化に追随できない	高（計算過程が明快）
回帰分析 Regression	売上を、価格や販促などの要因の関数として表現する	要因の影響度を数値で説明したい場合	要因間の相関が強いと係数の解釈が不安定になる	高（要因ごとの寄与が見える）
時系列分析 Time Series	実績をトレンド・季節性・不規則変動に分解して将来へ延長する	明確な周期性がある商品・サービス	周期を捉えるため、複数年分の履歴が必要	中（構成要素は分解可能）
機械学習 Machine Learning	多数の要因と非線形な関係、要因の組み合わせ効果を学習する	要因が多く、対象点数が多い（多SKU・多拠点）場合	データ量が不足すると過学習を起こし、実運用で崩れる	中〜低（要因の重要度は算出可能）

生成AIの役割 — 数値予測そのものではなく、予測業務の「前後工程」を担う

前工程：材料の整備

商品名や取引先名の表記揺れの統合、非定型なテキスト情報（営業日報・問い合わせ内容など）の分類・要約により、予測に使える形へ整える。

後工程：解釈と共有

予測値の変動要因を文章で説明し、部門別のレポートを自動作成する。数値を読み解く負担を下げ、現場で使われる状態に近づける。

誤解しやすい点

生成AIに数値予測を直接生成させる用法は、根拠の検証ができず再現性も担保されないため、業務判断の基礎としては推奨されない。数値の算出は統計・機械学習モデルが担う。

注記　事実：予測手法は移動平均・回帰・時系列・機械学習に大別される／解釈：高度な手法が常に優位ではない／提案：簡便手法をベースラインに設定し、上回るかで採否を判断する

AI予測システムの基本構成

システムは5工程の連鎖であり、工数の大半は予測モデルではなく「収集」と「加工」に発生する。最終工程の業務判断が設計されていなければ、前4工程を整備しても業務指標は改善しない。

① データ収集

POS・販売管理・在庫・基幹システムから実績を定期的に取り込む。外部データ（気象・指標）もこの層で取得する。

主な検討事項
連携方式（API／ファイル）、取得頻度、保持期間、権限管理

② データ加工

欠損・重複・表記揺れを補正し、粒度を統一する。曜日・季節・販促などの説明変数を生成する層でもある。

主な検討事項
補正ルールの定義、異常値の扱い、マスタ統合の責任部門

③ 予測モデル

学習と推論を実行し、予測値を出力する。定期的な再学習と精度の記録を仕組みとして組み込む。

主な検討事項
予測期間・更新頻度、再学習の周期、精度低下時の検知方法

④ 可視化

予測値と実績、誤差の推移を業務担当が確認できる形で提示する。既存の帳票・画面への組み込みも選択肢となる。

主な検討事項
閲覧単位、アラート条件、既存業務画面との統合方式

⑤ 業務判断

発注・生産・目標設定などの意思決定に反映する。修正した場合はその理由を記録し、次の改善材料とする。

主な検討事項
自動反映と人の確認の線引き、承認権限、修正理由の記録方法

実績・修正理由をデータとして戻し、継続的に精度を改善する

工程別の工数配分イメージ（一般的な傾向・仮定値）



上図の配分は一般的な傾向を示す仮定値であり、実際の比率はデータ基盤の整備状況によって変動する。重要なのは「モデル構築が全体工数の一部にすぎない」という点であり、導入計画ではデータ整備の期間を十分に確保する必要がある。

注記　事実：予測システムは収集→加工→モデル→可視化→業務判断の5工程で構成される／解釈：工数の大半は前段のデータ整備に発生する／仮説：工数配分は上図の比率程度（仮定値）／提案：計画時にデータ整備期間を明示的に確保する

導入前に確認すべきデータ品質

データ品質の問題は、モデル構築段階ではなく着手前に判明させるべき論点である。とくに「表記揺れ」と「欠品期間の実績」は、放置すると精度が上がらないまま原因の特定に時間を要する典型例となる。

確認項目	具体的に確認すること	放置した場合に起きること	対応の方向
欠損	売上がゼロの日が「実際に売れなかった」のか「記録がない」のか区別できるか	需要を過小に学習し、慢性的な過小予測につながる	ゼロと未記録を別の値として区別する記録ルールを定める
重複	同一取引が複数回計上されていないか、取消・返品が二重に反映されていないか	水準が過大に学習され、在庫過多を招く予測が出力される	一意キー（日付・拠点・商品・伝票番号）で重複を検出する
表記揺れ 最頻出の障害	同一商品・取引先が複数のコードや名称で登録されていないか（全角半角、旧称、略称）	履歴が分断され、実際より短い期間しか学習できない	名寄せルールと統合後の正式コードを定義し、責任部門を決める
データ量	季節性を捉えるうえで十分な期間があるか（一般に2年以上が望ましい）	年周期を学習できず、季節商品の予測が大きく外れる	履歴が短い場合は、類似商品群をまとめて学習する方式を検討する
粒度	業務判断に必要な単位（日次／SKU／拠点別）で実績が保持されているか	予測が出ても発注単位に変換できず、業務に接続しない	先に業務判断の単位を決め、その単位に合わせて保持粒度を設計する
異常値	大口特売・災害・システム障害・欠品による特異な実績が識別できるか	一時的な事象が通常需要として学習され、予測が歪む	特異日フラグを付与し、除外か要因として扱うかを決める
更新頻度	必要な予測タイミングに間に合う頻度で実績が確定するか	予測はできても、判断が必要な時刻に間に合わない	業務の締め時刻から逆算し、データ確定と再計算の時間を設計する

とくに注意すべき点：欠品していた期間の売上は「需要が小さかった」のではなく「供給がなかった」結果である。欠品履歴を区別せずに学習すると、需要を過小に見積もり、欠品がさらに繰り返される悪循環に陥る。

注記　事実：確認すべき品質項目は欠損・重複・表記揺れ・データ量・粒度・異常値・更新頻度／解釈：表記揺れと欠品履歴が精度に与える影響が大きい／提案：着手前にデータ品質の点検を独立した工程として実施する

小さく始める導入ステップ

最初から全社適用を目指すのではなく、「特定商品」「一店舗」「一営業部門」など効果を測定できる範囲に限定して着手する。対象を絞ることで、失敗した場合の影響を抑えつつ、効果の因果関係を確認できる。

導入ロードマップ（期間はいずれも仮定値。対象範囲とデータ整備状況により変動する）

ステップ	1か月目	2か月目	3か月目	4か月目	5か月目	6か月目～
① 対象業務の選定	検証準備・PoC					
② データ確認・整備	検証準備・PoC	検証準備・PoC				
③ PoC（試験的検証）			検証準備・PoC	検証準備・PoC		
④ 精度検証・評価				評価・展開	評価・展開	
⑤ 業務への組み込み・展開					評価・展開	本格運用

検証準備・PoC　評価・展開　本格運用

① 対象業務の選定

効果が金額で測れて、判断者が明確な業務を1つ選ぶ。

この段階の成果物
対象範囲の定義書、改善したい指標と現状値

② データ確認

前ページの品質項目を点検し、不足を補う範囲を決める。

この段階の成果物
データ点検結果、名寄せ・補正ルール、抽出手順

③ PoC

限定範囲で予測を作成し、従来手法と並走して比較する。

この段階の成果物
予測値と実績の比較記録、現場担当者の使用感

④ 精度検証

誤差指標と業務指標の両面で、従来比の改善を確認する。

この段階の成果物
精度評価レポート、許容誤差の設定、継続判断

⑤ 業務への組み込み

既存の業務手順・帳票に組み込み、対象範囲を段階的に拡大する。

この段階の成果物
業務手順書、運用体制、精度の定期モニタリング

注記　事実：導入は対象選定→データ確認→PoC→精度検証→業務組み込みの順で進む／仮説：所要期間は約6か月（仮定値）／提案：効果が金額換算でき判断者が明確な業務を1つ選び、そこから拡大する

予測精度の評価方法

精度は絶対値では評価できない。判断すべきは「従来の予測方法をどれだけ上回ったか」と「業務が許容できる誤差の範囲に収まっているか」の2点であり、指標の数値そのものが目標になってはならない。

基本となる誤差指標 — 用途に応じて使い分ける

指標	意味	適した使い方	留意点
MAE 平均絶対誤差	予測と実績の差（絶対値）の平均。単位は個数・金額のまま	「平均で何個ずれるか」を現場と共有したい場合	単位が異なる商品同士では比較できない
MAPE 平均絶対誤差率	誤差を実績で割った比率の平均。単位は百分率	商品・拠点をまたいで精度を横並び比較したい場合	実績が小さい・ゼロの商品では値が極端に大きくなる
RMSE 二乗平均平方根誤差	誤差を二乗して平均し、平方根をとった値	大きな外れを特に避けたい業務（欠品が致命的な商品）	少数の異常値に結果が強く引っ張られる
バイアス 誤差の偏り	符号をそのまま平均し、上振れ・下振れの偏りを見る	慢性的な過大・過小予測の有無を確認したい場合	上下の誤差が相殺され、絶対的な精度は測れない

評価は3つの観点で行う — 指標値のみでは、導入の是非を判断できない

① 従来予測との比較

同じ期間・同じ対象で、従来の予測方法と誤差を比較する。移動平均などの簡便な手法を基準とし、それを上回らない場合はAI導入の妥当性を再検討する。

② 許容誤差の設定

業務が耐えられる誤差の幅を、指標を見る前に業務側で決める。安全在庫でどこまで吸収できるかを起点に、商品区分ごとの基準を定義する。

③ 業務指標での確認

最終的な判断根拠は、欠品率・廃棄率・在庫金額・作業時間といった業務指標の改善である。誤差指標が改善しても業務指標が動かなければ、運用側に原因がある。

注記　事実：主な誤差指標はMAE・MAPE・RMSE・バイアス／解釈：指標値の絶対水準では良否を判断できない／提案：許容誤差を業務側で先に定義し、従来手法との比較と業務指標の改善で評価する

AI予測でよくある失敗

失敗の多くは技術的な要因ではなく、目的設定と運用設計の欠落に起因する。とくに「精度だけを追う」ことと「現場が使わない」ことは連動して発生し、投資が業務成果に結び付かない状態を生む。

失敗1　精度だけを追いかける

起きていること

誤差率の改善が目的化し、数値をわずかに良くするための検証が長期化する。一方で、業務指標は着手時点から変わらないまま推移する。

回避の方向

改善対象の業務指標（欠品率・在庫金額など）を先に1つ決め、誤差指標はその手段として扱う。許容誤差に到達した時点で検証を終える。

失敗2　現場が予測を使わない

起きていること

予測値は出力されているが、担当者は従来どおり自身の判断で発注する。根拠が説明されず、外れた際の責任の所在も不明確なためである。

回避の方向

既存の業務画面・帳票に組み込み、予測の変動要因を併記する。修正した場合は理由を記録する運用とし、責任分担を明文化する。

失敗3　外部要因を考慮しない

起きていること

競合の出店・価格改定、制度変更、天候の急変などが反映されず、環境が変わった局面で予測が大きく外れ、信頼が一度で失われる。

回避の方向

モデルが扱えない事象を事前に列挙し、人が上乗せ補正する手順と権限を定義する。補正の実績も記録し、次期の改善材料とする。

失敗4　運用が属人化する

起きていること

導入担当者だけがデータ更新と再学習の手順を把握しており、異動や退職を機に精度が劣化したまま放置される。

回避の方向

再学習の周期・精度の点検頻度・異常時の対応を手順書化し、担当を複数名に分散する。精度低下の検知は自動化を前提に設計する。

注記　事実：主な失敗要因は精度偏重・現場不使用・外部要因の無視・属人化／解釈：技術要因ではなく目的設定と運用設計の欠落に起因する／提案：着手時に業務指標・運用手順・責任分担を同時に定義する

導入を成功させるポイント

成功の条件は、予測の目的を業務判断の単位まで具体化し、人の判断を残したうえで、精度と運用を継続的に見直す体制を置くことにある。導入は一度の構築ではなく、運用しながら改善する取り組みである。

① 予測の目的を明確化する

「予測精度を上げる」ではなく、「どの判断を、どの単位で、いつまでに改善するか」まで具体化する。

定義すべき4項目

- 対象業務と判断者（誰が何を決めるか）
- 予測の単位と期間（SKU・日次・4週先など）
- 改善対象の業務指標と現状値
- 許容できる誤差の幅

② 人の判断と組み合わせる

AIは過去の規則性を扱い、人は過去に例のない情報を扱う。両者の担当領域を分けることが前提となる。

役割分担の考え方

- AI：定常需要の水準・季節性・曜日効果
- 人：新商品の初動、制度変更、突発事象
- 人：予測の採否と補正、その理由の記録
- 仕組み：補正記録を次期の学習材料に戻す

③ 継続的に改善する

需要構造は時間とともに変化する。構築時の精度は維持されない前提で、点検の仕組みを組み込む。

運用に組み込む4項目

- 誤差の定期モニタリングと閾値アラート
- 再学習の周期と実施責任者
- 予測が外れた事例の振り返り
- 対象範囲の段階的な拡大判断

着手対象の優先順位 — 効果の大きさと実現の難易度で判断する



注記　事実：成功要件は目的の明確化・人の判断との併用・継続的改善／解釈：構築時の精度は維持されないため運用設計が必須／提案：効果大・難易度低の業務から着手し段階的に拡大する

まとめ — 導入前チェックリスト

AIによる予測は、未来を完全に当てる手段ではなく、経営と現場の判断材料を増やし、在庫過多・欠品・機会損失を減らすための仕組みである。全社導入を前提とせず、効果を測定できる範囲から始めることが定着の要件となる。

AI予測 導入前チェックリスト — 着手判断のための10項目

1	**目的**	改善したい業務判断と、その判断者が特定されているか	□
2	**対象範囲**	特定商品・一店舗・一部門など、効果を測れる範囲に限定できているか	□
3	**評価指標**	改善対象の業務指標と、その現状値を把握しているか	□
4	**許容誤差**	業務として耐えられる誤差の幅を、業務側で定義できているか	□
5	**データ期間**	季節性を捉えられる期間（目安2年以上）の実績履歴があるか	□
6	**データ粒度**	業務判断に必要な単位（日次・SKU・拠点別）で実績を保持しているか	□
7	**データ品質**	表記揺れ・重複・欠品履歴の扱いについて、点検と対応方針があるか	□
8	**比較基準**	従来の予測方法を基準値として、同条件で比較する準備があるか	□
9	**運用設計**	予測の採否・補正の権限と、修正理由の記録方法を決めているか	□
10	**継続体制**	再学習の周期・精度点検の頻度・担当を複数名で担保できているか	□

まずは上記10項目のうち「1・2・3」が定まっているかをご確認ください。この3点が明確であれば、着手は可能です。

支援サービスのご案内

現状のデータ状況と業務課題を確認し、着手対象の選定から効果検証までを段階的にご支援します。

主な支援メニュー

- 現状診断（データ品質・業務プロセス）
- 対象業務の選定と効果試算
- PoCの設計・実施・精度評価
- 業務への組み込みと運用体制の設計
- 運用開始後の精度モニタリング支援

次のステップ

1	左記10項目のうち「目的・対象範囲・評価指標」の3点を確認する
2	対象候補の業務を1つ挙げ、保有データの期間と粒度を確認する
3	次ページの窓口までご連絡ください（現状診断からご相談可能です）

注記　事実：本資料の各章で提示した論点を10項目に整理／解釈：3点が定まれば限定範囲での着手が可能／提案：目的・対象範囲・評価指標の3点を先に確定してから着手する

お問い合わせ

現状のデータ状況とご検討段階に応じて、対象業務の選定から効果検証までを段階的にご支援します。導入判断の前段階のご相談も承ります。

ご連絡先

COMPANY

Start Challenge Consulting co., ltd.

挑む力が、世界を照らす

メール	**info@startchg.com**
担当	平出
ご相談方法	上記メールアドレスまでご連絡ください（オンライン面談も可）

ご相談いただける内容の例

現状診断	保有データの期間・粒度・品質を点検し、AI予測の適用可能性を評価する
対象業務の選定	効果が測定でき判断者が明確な業務を特定し、期待効果を試算する
PoCの設計・実施	限定範囲で予測を作成し、従来手法と並走して精度と業務影響を検証する
業務への組み込み	既存の業務手順・帳票への反映と、運用体制・責任分担の設計を支援する
運用後の改善	精度の定期モニタリング、再学習の運用、対象範囲の拡大判断を支援する

ご連絡の際に「対象としたい業務」「保有データの概要」「改善したい指標」をお知らせいただけますと、初回のご相談から具体的な検討に入ることができます。

CLOSING MESSAGE

AI予測の目的は、未来を当てることではなく、判断材料を増やすことにあります。

まずは一つの商品、一つの店舗、一つの部門から。効果を測れる範囲での着手を、伴走してご支援します。