

# 製造業のAIエージェントを1ヶ月で。

パッケージ導入でも、個別開発でもない。  
今あるシステム・データをそのまま使って、  
「地図」でAIとつなぐ

# こんなことが、起きていませんか？



## 熟練者の引退で、技術が消える

「あの人に聞けば分かる」が通じない。  
判断ノウハウ・勘所が残らないまま失われる。



## 社内の答えに辿り着けない

図面、報告書、Excel、議事録、チャット——情報は散在し、毎回ゼロから考え直している。



## 設計・見積・提案が遅い


類似案件の参照も図面チェックも属人化。  
若手の立ち上がりに数年。



## AIを入れたが、業務の本丸に効かない

Copilotやチャットボットは簡単な質問回答だけ。  
設計・製造・保守に届いていない。

# 設計から保守まで、各社独自の業務をAIエージェントで自動化



AIエージェントが、  
今あるシステム・データを使って業務を遂行



探す・活用



図面を解説



関係を辿る



最適化・予測

最短  
1ヶ月で  
立ち上げ

# 組立系製造業におけるユースケース

人がPC上で行う業務なら、AIで実現可能。但し、ROIが成り立つ領域が対象

| 技術▶<br>▼工程    | 探す・見つける + 活用する<br>LLM + RAG (+ナレッジグラフ)                        | 図面を解読する<br>VLM + RAG + ナレッジグラフ                              | 関係を辿って原因に迫る<br>LLM + ナレッジグラフ + RAG                            | 組合せを最適化する<br>最適化ソルバ + LLM                                  |
|---------------|---------------------------------------------------------------|-------------------------------------------------------------|---------------------------------------------------------------|------------------------------------------------------------|
| 設計            | <b>過去設計の流用さがし</b><br>類似形状・仕様の過去設計を横断検索。流用可否と注意点まで提示し属人化を解消    | <b>検図の支援</b><br>図面・仕様・社内基準をVLMで読解。規格・法規・過去不具合との差異を自動指摘      | <b>設計変更の影響波及</b><br>1件の変更が部品・製品・取説・治具のどこに波及するか関係を辿り修正漏れ防止     | <b>部品選定・組合せの最適化</b><br>コスト・在庫・互換・調達性の制約から最適な組合せ候補を順位つきで提示  |
| 調達・試作<br>量産準備 | <b>供給遅延・部品EOLを先読み</b><br>メール・通知から遅延やEOLを検知。影響部品と代替候補・打診文面まで生成 | <b>図面 → 工程のたたき台</b><br>図面から加工手順・段取り・必要設備のたたき台を生成し技術継承を支援    | <b>部品共通化の候補と効果</b><br>全製品のBOMを横断し乱立部品の共通化候補を抽出。削減見込みも試算       | <b>試作前に性能・耐久を予測</b><br>過去試験データから性能・耐久を予測。試作回数とリードタイムを削減    |
| 製造・品質         | <b>現場メモ・口頭 → 保全起票</b><br>現場メモや口頭報告から保全・改善起票を自動生成。担当割当てまで      | <b>検査要領の生成・照合</b><br>図面・検査基準から検査要領を生成。不適合品は図面と照合し該当箇所を特定    | <b>不具合原因の特定と横展開</b><br>工程・部品・ロット・過去対策の関係を辿り原因特定。横展開先まで        | <b>生産順序・割当の最適化</b><br>納期・在庫・段取り・設備能力の制約から生産順序と人員割当てを最適化    |
| アフター<br>サービス  | <b>故障の切分け・整備手順を即提示</b><br>症状・エラーコード・稼働履歴から想定原因と整備手順を提示        | <b>補修部品の適合チェック・展開</b><br>マニュアル・部品図を読解し機種・年式・仕向けへの適合可否を判定・展開 | <b>市場不具合・クレームの原因究明</b><br>共通原因を早期発見し影響機種・ロット・在庫を辿って特定。回収判断を支援 | <b>稼働ログ → 予兆 → 先回り</b><br>稼働ログから交換時期や故障予兆を見極め部品補充・訪問を先回り計画 |

# 化学・素材系製造業におけるユースケース

人がPC上で行う業務なら、AIで実現可能。但し、ROIが成り立つ領域が対象

| 技術・<br>▼工程         | 探す・見つける + 活用する<br>LLM + RAG (+ナレッジグラフ)                              | 性能・品質を予測する<br>機械学習 + LLM                                          | 関係を辿って原因に迫る<br>LLM + ナレッジグラフ + RAG                                          | 条件・配合・運転を最適化する<br>探索・ベイズ最適化・ソルバ<br>+ LLM                        |
|--------------------|---------------------------------------------------------------------|-------------------------------------------------------------------|-----------------------------------------------------------------------------|-----------------------------------------------------------------|
| 研究・処方              | 過去処方・実験の横断さがし<br>類似組成・目標物性の過去実験<br>や文献を横断検索。流用可否と<br>注意点まで提示し属人化を解消 | 配合条件 → 性能を予測<br>過去の実験データから機械学習<br>で性能を予測。試作前に初回精<br>度を高め修正サイクルを削減 | 物性ばらつきの要因探索<br>組成・原料ロット・条件と物性<br>の関係を辿り、効く因子の候補<br>を提示                      | 目標性能 → 配合条件を探索<br>予測モデルの逆問題として、目<br>標性能と制約から試すべき配合<br>・条件の候補を提示 |
| 試作・<br>スケール<br>アップ | 試作記録の再利用<br>小スケールの成功条件・失敗事<br>例を検索し、再現に必要な条件<br>を提示                 | スケールアップ後の品質を予測<br>ラボデータから実機での歩留・<br>品質を予測し、試作回数とリー<br>ドタイムを削減     | ラボ⇄実機の差異要因を辿る<br>スケール間の物性差を、原料・<br>装置・条件の関係から要因分解                           | 実機運転条件のたたき台生成<br>目標品質と設備制約から、実機<br>での初期運転条件のたたき台を<br>生成         |
| 製造・運転              | 現場メモ・口頭 → 起票<br>運転日誌や口頭報告から保全・<br>改善起票のドラフトを生成。担<br>当割当まで           | 出荷前の品質逸脱を先読み<br>運転・原料データから、出荷前<br>に品質逸脱リスクを予測（見え<br>ない不良の先読み）     | オフスペックの原因究明と横<br>展開<br>バッチ・原料ロット・運転条件・過<br>去対策の関係を辿り原因特定。同一<br>原因の他銘柄・ロットまで | 運転条件・生産計画の最適化<br>品質規格・コスト・設備能力の<br>制約から運転条件と生産順序を<br>最適化        |
| 品質・出荷              | 検査要領の生成・照合<br>規格から検査要領を生成。オフ<br>スペック品は規格と照合し該当<br>項目を特定             | -                                                                 | 市場品質問題・クレームの原<br>因究明<br>共通原因を早期発見し影響銘柄・ロ<br>ット・在庫を辿って特定。回収判断<br>を支援         | -                                                               |

# これらのAIは、既に現場で成果を出している（組立系）

## 検図・図面検索支援

### 大手機械メーカー

図面からVLMで特徴抽出し自然文検索。  
仕様の漏れ・誤り候補を自動警告

## 不具合原因解析

### 大手自動車メーカー

初報から設計・品質文書を自律探索し、  
根拠付きで原因仮説。3年目経験者と同等

## 構造物設計の最適化

### 大手エンジニアリング

数百の制約下で数量・配置・寸法を最適  
化。専門設計者比で施工コスト削減

## 生産スケジューリング

### 精密機器メーカー

強化学習で装置へワーク割当。従来手法  
で困難な条件でも良い計画を出力

# これらのAIは、既に現場で成果を出している（化学・素材）

## 配合条件からの性能予測

### 材料メーカー

過去の実験データから機械学習で性能を予測。試作前に初回試作の精度を高め、修正サイクルを削減

## 不具合原因解析

### 大手自動車メーカー

初報から設計・品質文書を自律探索し、根拠付きで原因仮説。3年目経験者と同等

## 目標性能からの配合条件探索

### 材料メーカー

化学反応モデルの推定とベイズ最適化で、次に試すべき配合・条件を提案。実験回数を削減

## 素材製造レシピの最適化

### 素材製造

実験を繰り返しデジタルツインを構築し、加工レシピ（各種パラメータの組合せ）を最適化

多くのAIが"本丸"に届かない理由は、実は一つ。

# 「データ」と「AI」を、どう繋ぐか。

“AIを賢く使う”とは、貴社のデータと事情をAIに理解させること。

ここには多くの時間とコストがかかりますが、私たちはこの壁を越えてきました。



## AIが読める形にない

図面・PDF・Excel・チャット。  
非構造化が大半で整備に年単位



## 汎用AIは業務を知らない

自社の用語・判断基準・経緯抜きでは現場で使えない




## ベンダー作業が重い・歯痒い

大規模PoC・長期チューニング。  
効果が出る前に予算切れ


# 解決の核は「コンテキスト層」

文書・情報群を“意味と関係”でつないだ地図。この上で、AIが人の仕事をこなす。

## 散らばった データ



## “意味と関係”でつなぐ = コンテキスト



## 地図の上でAIができる 4つのこと



探す・見つける＋活用する  
横断検索＋生成AI



図面・帳票を解読する  
画像・図面解釈AI (VLM)




関係を辿って原因・影響に迫る  
ナレッジグラフ



見通す・最適化する  
最適化ソルバ／予測


# デモ：データの地図を辿って、“真因”に迫る

## ① 質問 → データの"地図"を多段に辿って推論



質問例：「市場でSV-300に発火クレーム。原因部品と、同じ原因が潜む他機種・出荷ロットを洗い出し、リコール要否の一次判断レポートを」。AIが 文書→不具合→部品→機種→出荷 と関係を追って探索。

## ② 真因・影響範囲をレポートで出力



出力：真因候補（電解コンデンサ CAP-47）を特定し、影響4機種・推定約3,160台と推奨アクションを、根拠付きのレポートで提示。

※架空の組立製造業データによるデモ画面です。動くデモは、お打ち合わせにてご覧いただけます。

# なぜ1ヶ月で出来るのか？



## ① AIエージェント基盤を用意

データの接続・統合、意味と関係のインデックス化、検索、実行・権限管理まで、共通機能を予め整備



## ② 個社対応も、生成AIで自動化

「データ基盤構築」「エージェント設定」「運用改善」の個社対応も生成AI実施し、高速化




## ③ FDE体制

エンジニアが入り込み、パッケージの導入ではなく、"貴社仕様で動くAIエージェント"を作り切る

**最初の1業務は1ヶ月で稼働。以降は1～3ヶ月ごとに追加。**

# primeNumberのAIエージェント基盤

AIエージェントを実現する、基本的な仕組みを予めプロダクトとして用意



# 2,500社のデータを"扱ってきた"から、AIに最短で繋げる。



## 2,500社の現場知

TROCCO(データ統合)とデータ基盤構築で国内2,500社のデータを担当。業種ごとのデータの"クセ"、散在パターン、躰きどころを熟知。



## データ基盤×AIを一社で

「AIの会社」でも「データ基盤の会社」でもなく、その両方の技術と知見を持つため、“データはあるが繋がらない”が起きません。




## プロダクト化 + 個別対応

共通部分はプロダクト、固有部分は多様なプロフェッショナルサービスの提供によるノウハウを積んだAIで高速実装

データを知り尽くしているから、AIに渡すべきデータを最短で実装できる。

## 参考) 他社との違い

primeNumberは早さと柔軟さの両方を兼ね備えている



# まず、貴社の“AI活用箇所”を診断しませんか？

どの業務なら1ヶ月で動くか、ROIが成り立つか。  
無料の初期診断でご提示します。



## AI活用箇所 診断

効きどころとROIを  
可視化



## サービス資料

事例つきで詳しく



## デモのご相談

動くデモを個別に

# ユースケースの例

組立系 | 設計

## 検図の自動化

2D図面（PDF）をそのまま解読し、基準・仕様との差異を図面上に指摘。

共通 | 製造・品質

## 不具合の原因分析

複数の仮説を立て、関係を辿って裏を取り、原因の原因まで掘り下げる。

共通 | 保守・サポート

## 技術相談アシスタント

数百ページの製品資料を図表ごと読み解き、型式を絞って回答を下書き。

化学・素材系 | 研究・処方

## 配合条件・性能予測

試作前に性能を予測し、目標性能から配合候補を逆引きする。

共通 | 試作・量産準備

## 実験・試作の条件出し

ベイズ最適化で“次に試すべき条件”を提案し、試作回数を減らす。

共通 | 全工程

## 社内ナレッジ横断活用

骨格に文書を紐づけ、個別検索では届かない問いに関係を辿って答える。

# 製造業のAIエージェント - ユースケース①

## 検図の自動化

# 対象業務：検図の観点は多岐にわたり、工数がかかる

## 設計から検図までの流れ

1

### 要件確認・検討

顧客要件を確認し、FMEA（故障モード影響解析）等で仕様を検討

2

### 3D設計

形状・寸法を3D CAD で作成  
(CADの変更は大掛かりで難)

3

### 2D図面化（意図反映のため人が指定）

- ・1図面に複数の角度/部位。三面図・断面図など形式もまばらで、配置も流動的
- ・測定指示・試験条件などの仕様を文章で追記
- ・1製品に親子部品を含め何枚も

4

### 三重チェック

設計者→検図者→承認者が目視で突合

## チェックする観点は多岐にわたる

### 基準・作図の正しさ

線種・中心線・記号の重なり、JIS/社内基準への準拠、変更履歴の抜け漏れ

### 仕様・試験条件の記載

製品ごとに必要な測定指示・試験条件（温度/振動など）が要件・社内標準を満たしているか。逆に過剰ではないか

### 図面どうしの整合

親図面と子部品、仕様書との突合。矛盾や測定指示に漏れがないか（親部品側が要計測ならば、接合する子部品側も要計測等）

そして、これらの要件は会社独自のもので、更新していく必要がある

# 解決策：AIが図面を読み、指摘を“下書き”する

2D図面（PDF）をそのまま解読し、基準・仕様と照らして指摘。最終判断は人が行う。

## 仕組み

### 2D図面（PDF）

CAD不要。過去図面もPDFで

### AIが解読（VLM）

線種・記号・寸法・注記の文章まで

### 基準・仕様と照合

逸脱・抜け・不整合を検出

### 図面上に指摘を下書き

吹き出しで提示 → 人が最終判断

### コンテキスト層


JIS / 社内基準

過去図面/検図履歴から  
抽出したルール

仕様・FMEA

製品コード⇔要件

## 出カイメージ



※架空の図面イメージです。指摘は人の確認を前提とした候補提示です。

**持ち出し・クラウド不可の環境でも** 図面を外に出さない構成での実現も  
相談可能です（要件により構成・費用は変わります）。

# 検図ルールは、人とAIで“育てる”

一度きりの構築ではなく、使いながら精度を上げていく。  
人がルールの主導権を持ち、AIが精度を底上げする。



🔄 **使うほどに、精度が上がる。** 明文化されていないルールも、運用の中で少しずつ形式知に変えていける。

※AIの提案は候補提示であり、承認・最終判断は人が行います。

# 製造業のAIエージェント - ユースケース②

## 不具合の原因分析

# 対象業務：原因分析は、仮説→探索ループを回す仕事

## 不具合の受付

症状・発生状況・ロット

1

### 経験と勘で、あたりをつける

「たぶんあの部品／あの工程」。ベテランは絞れるが、若手は絞れない

2

### どこを見るか思案する

出荷・検査・工程・部品・過去是正…  
どの記録を見るか都度考える

3

### 手作業で探して、突き合わせる

システムを行き来し、Excel・報告書を開いて目視で照合（時間がかかる）

4

### 確かめる → 違えばやり直し

外れたら、また①へ。当たりが出るまで試行錯誤を繰り返す

## この業務での難しい点

### 時間がかかる

1周ごとに手作業の探索。ループが何周もして、真因にたどり着くまで日数を要する

### ベテランに依存／巧拙の差が大きい


上手く回せるかは、仮説の幅・資料の在処によるため、経験と勘に依存。若手だけでは同じ所を堂々巡りしがち

### 探し切れず打ち切り

勘が外れ続けると、辿り切れずに“それらしい原因”で止めてしまう

# 解決策：AIが繰り返し“関係”を辿って真因に迫る

AIが複数の仮説を立て、検証・棄却を繰り返しながら、原因の原因まで多段で掘り下げる。



# 効果：若手の探索を底上げし、ベテランの負荷を減らす

AIはベテランの勘には及ばない。だが、若手が時間をかける探索を、速く・根気強く・漏れなく回す。

大事なのは“賢さ”より“調べ切る根気”。同じAIでも「それらしく答える」と「粘り強く裏を取る」のは違う。



**Before:**

一発で“それらしく”答える

- × 一度検索して、上位の答えを返すだけ  
仮説の検証も、外れた筋の棄却もしない
- × 浅い階層で止まる  
目についた原因で止まり、原因の原因まで辿らない
- × 分からなくても、それっぽく答える  
根拠のない断定が、誤った対策・再発を生む



**After:**

仮説を検証し、裏を取り切る



複数の仮説を立て、検証・棄却

外れた筋は捨て、成り立つ筋だけ深掘り



関係を辿り、多段で掘り下げる

原因の原因まで、仮説の更新が止まるまで遡る



分からなければ“不明”と返す

確信度と根拠つき。誤った断定をしない

若手でも、根拠つきで真因に近づける。ベテランは“最後の判断”に集中できる。 AIは下調べを回す道具。最終判断は人が行います。

# 製造業のAIエージェント - ユースケース③ 施工・技術相談アシスタント

# 対象業務：技術相談は“探して・考えて・つなぐ”仕事

代理店・施工店からの技術相談に、担当者が資料を探し、答えを組み立て、難しい案件は多部門へ伝言でリレーする。

## いまの相談対応の流れ

1

### 現場から技術相談

代理店・施工店が、現場の困りごとを担当者へ問い合わせ

2

### 分厚い資料を探す

数百ページの製品資料から、該当箇所を手探りで探す

3

### 答えを組み立てる

図表・式・型式を読み解き、回答を自分で考える

4

### 難しければ、多部門へ

先輩→支社→本社技術→開発と伝言でリレー（往復が重なる）

## 答えにたどり着けない“難所”

### 図表が読めない

寸法・グラフ・接続図など、文章になっていない情報が答えの鍵になる

### 型式の取り違い／複数製品の突合

似たシリーズが並び別型式を答えがち。組合せ・交換・副作用まで見る必要

### 過去の経緯・制度が絡む

過去のやり取りや、資料にない外部知識を踏まえないと答えられない

# 解決策：相談を解釈し、資料を読み解き、答え方を制御する

AIが図表ごと資料を読み、型式を絞り、“答えてよいか”まで判断する。最終判断は人が行う。

## ① 相談を解釈する

### 登場する型式を特定

似た型式・シリーズを正しく区別

### 相談の意図・前提を読む

何を知りたいか、前提は何か。  
相談が曖昧なら逆質問。

### 必要な処理に分解

計算・図・突合など見極め

### 社内/専門用語変換

用語辞書で変換

## ② 資料を読み解く（コア）

### 図表を画像として読む

寸法・グラフ・接続図を读取

### 型式で対象資料を絞る

該当製品の資料だけ参照

### 複数資料を突き合わせる

組合せ・交換・副作用を照合

### 計算・妥当性を確認

式に値を当て、範囲を検証

## ③ 答え方を制御する

### 答えてよいか判断

確信が持てない相談は答えない

### 対象外は人へ

適切な担当へ引き継ぐ

### 根拠つきで候補提示

参照ページを添えて下書き

## 肝は“答える手前”。

図を読む・型式を絞る・突き合わせる・答えてよいか判断する。ここを外すと、それらしい誤答になる。難しい相談はAIが手順を分解し段階的に照合（Agentic）。

# 効果：探す時間を減らし、答えの質をそろえる

キーワード検索の先へ。図・型式・履歴を踏まえ、確かめた答えを返す。

同じ資料参照でも「それらしい箇所を出す」と「読み解いて裏を取る」のは違う。



## キーワードで検索するだけ

### × 図表は読めない

文章しか探せず、寸法・グラフは人が確認

### × 型式を区別しない

似たシリーズの別型式がヒットする

### × 候補が多すぎる

“この辺にありそう”が大量に出て絞れない



## 読み解いて、確かめて答える (pN)



### 図表を画像として読む

寸法・グラフ・接続図まで読み取る



### 型式で正しく絞る

対象製品の資料だけを参照する



### 答えてよいか判断

確信のない相談は人へ、無理に答えない

## 答えを“探す”から“確かめる”へ。

答えられない相談は人へ回し、答えた相談はナレッジとして育てていく。 ※出力は候補提示。最終判断は人が行います。

# 製造業のAIエージェント - ユースケース④

## 配合条件・性能予測

# 対象業務：配合の“当たり”は経験と試作回数しだい

配合→試作→評価→修正の繰り返し。目標に到達するまでの回数に個人差が大きい（属人化）。

## 配合設計・試作の繰り返し



## なぜなかなか答えにたどり着かないのか

### 組合せが膨大

顔料・樹脂・添加剤の組合せ＋製造条件。試せる数は限られる

### 経験と勘に依存（属人化）

到達までの試作回数に個人差。担当が変わると再現が難しい

### データが活きていない

過去のレシピ・実験報告は蓄積されるが、次の設計に活かしていない

# 解決策：性能を“予測”し、配合を“逆引き”する

蓄積した実験データを学習。試す前に性能を予測し、狙いから配合候補を導く。

活用するのは「数値（実験条件・性能）」と「文章（補足・考察）」。「予測→逆引き」の順で育てる。

## 案① 性能予測モデル

配合条件 → 性能を予測（試作回数の削減）



**Step1** 実験結果（数値）を機械学習

**Step2** 実験報告の文章も読み、予測を補正

試す前に性能が分かる → 初回試作の精度を上げ、修正回数を減らす

## 案② 配合条件探索モデル

目標性能 → 配合候補を逆引き（予測の逆解析）



「この性能を出すなら、この配合から試すとよい」を提示

※ 案①が十分な精度で成立して初めて可能。まず①、次に②の順で進める。

## 予測 → 逆引き の順で育てる。

まず「試す前に分かる」を作り、成立したら「狙いから配合を導く」へ広げる。 ※提示は候補。採否・実施は人が判断します。

# 効果：試作回数を減らし、属人化を解消する

数値だけの予測と、文章の知見まで使う予測では届く範囲が違う。

経験・勘に依存した判断をデータで補助し、担当者以外でも一定水準で調整できるようにする。



## Before: 数値データだけで予測

- × **定型データに限られる**  
一元管理されたレシピの数値しか使えない
- × **考察が捨てられる**  
「なぜ失敗したか」の知見が予測に入らない
- × **精度が頭打ち**  
数値だけでは説明しきれない現象がある



## After: 数値 + 文章の知見

- ✓ **報告書の考察も読む**  
散在する実験報告の文章を予測に反映
- ✓ **属人知を形式知へ**  
担当者の勘所を、データとして引き継ぐ
- ✓ **少ないデータを補う**  
数値が足りない所を、文章の知見で補完

### 属人化を、データで解く。

引き継ぎ時も過去実績を参照でき、技術者の引退・異動に伴うリスクを緩和する。 ※効果（回数削減）は個別に試算します。

# 製造業のAIエージェント - ユースケース⑤

## 実験・試作の条件出し

# 対象業務：実験・試作の条件出しは総当たりになりがち

変えられる条件が多く、組合せは膨大。頼りは経験と勘。

## 実績・試作の条件出しの流れ



## 難しさ：変えられる条件が、とにかく多い

### 射出成形

樹脂温度／金型温度／射出速度／  
保圧／冷却時間

### 熱処理

加熱温度／保持時間／冷却速度

### 溶接・接合

電流／電圧／速度／シールドガス

### 表面処理 ・接着

温度／時間／濃度／前処理

⋮

## 組合せ爆発


条件が数個 × 各数水準でも全通りは数百～数千。

全部は試せず、勘で当たりをつけるしかない。


※前提 データが十分あれば、AIの予測だけで条件を導ける（マテリアルズ・インフォマティクス=MI）。ここでは“データが少ない・実験が要る場合”を扱う。

# 解決策：実験計画のループで、実験・試作を減らす

これまでの結果からベイズ最適化で確率分布を予測。残り回数から”次に試すべき条件”をAIが提案



## “次に試すべき条件”を導くメカニズム



# 効果：実験・試作回数を削減できる（早く答えに辿り着く）

条件が膨大でも、効きそうな条件に“当たりをつけて”試せる



**Before:**

勘に頼る／片っ端から試す（総当たり）

× 回数がかさむ

組合せが多いほど、試作コストと時間が膨らむ

× 過去を活かせない

前の試作結果を、次の条件選びに活かしきれない

× 勘に依存

どこを次に試すかは、担当者の経験と勘頼み



**After:**

データとAIで“当たり”をつける



少ない実験・試作で最良へ

確率分布から、次に試すと効く条件を提案（複数可）



今あるデータのまま

個人のExcel・報告書の過去試作を学習の元手に



探索と活用を自動で調整

残り試行数に応じ、攻めと詰めを切り替える

**少ない試作で、最良に近づく。** 材料・成形だけでなく、封止・接着・表面処理など“条件出し”のある工程に広く応用可能

## 製造業のAIエージェント - ユースケース⑥

# 社内ナレッジ横断活用

散らばったデータを、意味と関係の“地図”にする。  
個別検索では届かない横断的な問いに、関係を辿って根拠つきで答える。

# 社内の“モノ・コト”を、関係でつなぐ

製品・部品・工程…（意味）と、図面・報告書・メール…（文書）を1つの地図に。

## 地図の部品は2種類

### つながりの骨格


製品・部品・工程・設備・ロット…＝構造化データの実体とその関係

### 紐づく文書・記録

図面・仕様書・報告書・メール・チャット…＝非構造化データ

### 骨格が“地図”になる。


散らばった文書・メール・チャットが、正しい場所に紐づく。個別のシステムを横断して辿れる。



※ 本デモのデータはすべて架空です。

# 個別検索では届かない問いに、辿って答える

例：1件の発火クレームから、真因部品と“他機種への広がり”まで。



## 辿った経路（個別検索では出ない）

### 発火クレーム（CLM-301）

- 8D報告 → 不具合「発火」
- 疑い部品を絞込み（電解コンデンサ CAP-47）
- 表記ゆれを名寄せ（発煙／半角カナ）で再探索
- 原因ロット CL-2407（製法変更後）に集中
- 搭載する4機種・出荷を横断
- 影響台数を推計 → リコール一次判断




## そのままアクションへ（下書き）

- ・ レポート 真因・影響範囲・推定台数を根拠つきで
- ・ は正メール 仕入先へ8D要求の下書き
- ・ 起票 リコール調査タスクを登録

※出力は候補提示。採否・実行は人が判断します。表示はアクセス権限に従い、権限のない情報は出しません。

# “地図”は、3段階でつくる

既存システムで骨格をつくり、文書を取り込み、本文を解析して紐づける。



## ① 構造化データで骨格をつくる

ERP・PLM・MES等のマスタ・実績から、意味ノードと確かな関係（BOM・工程・供給・出荷）を生成

## ② 文書を取り込み、文書間の関係をつくる

ファイル・メール・チャットを取り込み、フォルダ階層・更新日時から親子・新旧を関係づけ（旧版も保持）

## ③ 本文を解析し、意味ノードに紐づける

本文から部品・不具合・ロット等を抽出・紐づけ。独自用語辞書で表記ゆれ・略語を正規化

独自用語辞書で表記ゆれ・略語を正規化。 判断に迷う文書は「確認チケット」→人が判断。随時・非同期で更新し続ける（全自動ではない）。

アクセス権限に従って参照。 グラフが持つのは“関係”のみ。本文は元システムの権限（ACL）に従って参照し、権限のない情報は表示しない。

# 進め方：全社一括ではなく、業務ドメイン別につなぐ

骨格（構造化データの繋がり）が“地図”になり、散在する文書・メール・チャット（非構造化）が紐づく。

## 課題

### 全社データを

### 一気に一元管理？

- × 対象が広すぎて終わらない
- × 権限・機密が入り組む

- × （特に大手ほど困難）

- × 要らない範囲まで抱える


- × 結局“使われない基盤”に

→ 現実的でない

だから

## 対応：業務ドメイン別に、必要な範囲からつなぐ

その業務に関係するデータ・関係だけを対象に。ドメインをまたぐ実体（設備・ロット・BOM等）は共有する。



# 探すのではなく、“辿れる”土台をつくる

一度つくった地図は、部門を越えて使い回せる。

同じ「社内情報の活用」でも、個別検索と“関係を辿る地図”では届く範囲が違う。

## Before: 個別に探す（検索）

- × システムごとに分断  
ERP・図面・メール…を別々に探し、頭の中でつなぐ
- × 表記ゆれに弱い  
言葉が違うと、関連する情報を取りこぼす
- × 退職とともに失われる  
“誰が何を知っているか”が個人に依存

## After: 関係を辿る“地図”

- ✓ 部門・システムを横断  
1つの入口から、関係を辿って横断的に引ける
- ✓ 表記ゆれを名寄せ  
言葉が違っても、同じ実体としてつながる
- ✓ つくった土台は使い回せる  
業務ドメイン別に小さく始め、少しずつ広げる

**探すのではなく、辿る。** 必要な業務から小さく始め、つくった地図を全社の土台に育てていく。

# 製造業のAIエージェント 御社の業務から、 AI活用テーマを一緒に見つけます

“ありもの”を当てはめるのではなく、  
御社の業務内容から仮説を用意し、討議・探索します。

# AI活用テーマは、2つの方向から探す

両方向で候補を挙げ、ROI（効果 vs 投資）で優先テーマを絞り込む。



## ① AIで“できること”から

AIが得意なこと（探す・読む・辿る・予測・最適化）を起点に、当てはまる業務を探す。



## ② 業務の特徴から

業務量が多い・時間がかかる・属人的・抜け漏れが起きる・改善すると効果が大きな業務を起点に、AIで解けるかを検討する。

挙がった候補を

**ROIで絞る** 両方向で挙げた候補を、効果が投資に見合うか（ROI）で評価し、優先テーマを選ぶ。

# AIで“出来ること”と、その前提

人がPC上で作業・検討することであればほぼ何でも出来るが、解像度を上げるため、能力ごとに、成立には何が必要か、を押さえる。

| AIの能力 | 出来ること                                     | 必要な条件（前提）                          | 主な技術             |
|-------|-------------------------------------------|------------------------------------|------------------|
| 探す・書く | 文章を読んで探し、要約や下書きを作る（情報と時間があれば新人でも出来る作業の代替） | 目的・指示が明確／根拠となる文書がある                | 生成AI・LLM（検索/RAG） |
| 読み取る  | 図面・帳票・写真などの内容を読み取り、決めた項目に構造化する            | 読み取る項目・判断基準が定義できる                  | 生成AI・LLM（画像/VLM） |
| 辿る    | 情報どうしの関係を辿り、複数の情報源をまたいで答えを組み立てる           | 実体と関係の地図化（コンテキスト層）に必要な情報がある        | 知識グラフ + LLM      |
| 予測・判定 | 過去データの傾向を学習し、数値・良否・分類を推定する                | その傾向を導くのに、十分な学習データがある（データから類推できそう） | 教師あり学習           |
| 最適化   | 制約の中で、目的を最大／最小にする条件（パラメータ）を導く             | 決定変数・目的関数・制約を定義できる（数学orゲームの問題に出来る） | 数理最適化（学習と併用）     |

（参考）分類・傾向発見：分類・傾向が潜むデータ群から、類似度でまとめ、未知の傾向を見出す（教師なし学習）。探索的な分析に用いる。

※ AIでも「無から有」は生み出せません。出力を導く知見・情報（過去データ／社内文書／一般常識）が、どこにあるかが鍵です。

# 実現可否をクイックに検討し、ROIを見極める

## ①実現方法の超概要を検討する



## ②投資に見合う効果があるか？

**効果（どのくらい効くか）**  
削減工数／品質向上・抜け漏れ防止／  
人手不足・技術継承の回避

**VS**

**投資**  
構築・運用のコスト

# 進め方は、温度感に合わせて選べる

決まった型に押し込まず、対象業務と関わり方に合わせて設計します。

## A 仮説提言型 手軽

- 1 対象業務の超概要・スコープを伺う
- 2 「ここが候補では」と仮説を提示
- 3 仮説をヒントに膨らませ／取捨
- 4 優先施策を選び、具体化へ

向く：まず叩き台が欲しい／短時間で当たりをつけたい

## B ヒアリング／ ウォークスルー型

- 1 一連の業務をフロー／リストで整理
- 2 各工程に“AI化するなら？”を検討
- 3 ヒアリングと討議で候補を洗い出す
- 4 優先施策を選び、具体化へ

向く：特定業務・プロセスを、順を追って見たい

## C ボトムアップ型 じっくり

- 1 事例・考え方をレクチャー
- 2 その場 or 宿題で案を検討
- 3 出た案を討議・並び替え・膨らませ
- 4 優先順位付け・統廃合 → 具体化へ

向く：部・課のメンバー（5～20名）で広く募りたい

※ 弊社が全面的にリードする体制も、アドバイザーとして伴走する体制も選べます（自社主導も可）。

# まずは、御社の業務に即した仮説から。

業務の超概要をお聞かせいただければ、「こんなところにAIが効くのでは」という仮説をご用意します。  
その仮説を叩き台に、御社に合う進め方（前ページのA～C）で、有望なテーマを一緒に選んでいきます。

---

ご関心のテーマがあれば、お知らせください。この資料をご覧の担当者さまへ、後日あらためてご案内いたします。