

製造業の設計開発における 生成 AI 活用テーマ開拓のガイドライン

株式会社野村総合研究所 AI コンサルティング部
シニアコンサルタント 平原 一輝 … [a]

株式会社野村総合研究所 AI コンサルティング部
シニアコンサルタント 坂上 竜馬 … [b]

株式会社野村総合研究所 AI コンサルティング部
シニアコンサルタント 川名 拓己 … [c]



a | b
c |

1 はじめに

1) 製造業の設計開発業務における生成 AI 活用の 現状と可能性

2022 年 11 月に OpenAI 社が ChatGPT を発表
して以来、生成 AI は急速にユーザーを獲得し、さ
まざまな業界・業務での活用が進みつつある。製造
業の設計開発の領域でいえば、文章作成・要約・ア
イデア出しなどの基本的な用途に加えて、下記のよ
うな応用的なテーマでも活用が広がりつつある。

- 制御コードの自動生成：Schneider Electric 社
「Automation Manager」など
- Generative Design^{※1}による設計自動化：
Autodesk 社「Autodesk Fusion」など
- 熟練設計者ノウハウの形式知化・体系化：
LIGHTz 社「Blooplinter」など

これらの取り組みは、設計開発業務の効率化によ
る人件費削減やリードタイム短縮、革新的な製品に
よるビジネス創出、競合との差別化・製品ライフサ
イクルの最適化による収益性向上などの価値を創出
し得る。

2) 製造業の設計開発業務の特徴

製造業の設計開発業務は生成 AI による業務革新

が期待されている分野の一つである。これまではそ
の業務プロセスや業務データの複雑さゆえに業務革
新の難易度が高く、属人的な業務の進め方をベース
にせざるを得なかった。生成 AI はこれらの課題を
乗り越えられると期待されているが、その乗り越え
方を見ていく前に、そもそもの業務プロセスや業務
データの課題を確認しておく。一般に、設計開発の
業務やデータには下記のような特性があることが知
られている。

(1) 業務プロセスの複雑さ

製造業の中でもハードとソフトを組み合わせた設
計が必要となる自動車、電子機器、建設機械などの
業種では、機能モジュールが複雑化していることか
ら多くのチームが同時に開発を進行する必要があ
り、特に上流工程ではハード・ソフトをまたいだ調
整が多発する。そのため、業務フローが他と比べて
もより複雑で標準化が難しいケースが多い。

※1 AI アルゴリズムを使用して、ユー
ザーからの入力に基づき複数のデザインの
選択肢を生成し、評価する設計手法

(2) 膨大な非構造・非定型データ

前項(1)で述べた業務プロセスの複雑さは、蓄積されるデータの品質を低下させ、データ活用の難易度を上げてしまう。具体的には下記のような特徴がある。

① 量の膨大さ

ハード・ソフトを組み合わせた開発の場合、一つの設計開発案件で取り扱う設計ドキュメントは膨大となり、特定のデータベースに集約されていないケースが非常に多い。そのため、業務改革にあたり必要となるデータの把握・整理に多大なコストがかかることもある。

② マルチモーダル性を持つデータ

ハード・ソフトを組み合わせた開発では、CADデータや仕様書など複雑なグラフ・図表をとまなう設計ドキュメントが大半である。それらは非構造的かつ非定型性のため、従来の機械学習技術では適切な処理が難しい。

③ 標準化、定型化されていないデータ

従来の機械学習で比較的扱いやすかったテキストデータにおいても、上記のように標準化されていない業務プロセスのため、各ドキュメントもフォーマットが定型化されていないケースが大半である。

④ そもそもデータとして存在していない暗黙知

最後に、業務に必要な情報がそもそもデータとして起こされていないという状況も散見される。

(3) 長い製品ライフサイクルに起因した改善サイクルの長期化

プロジェクトで設計開発にかかる期間も他業界と

比較して長い傾向があり(数年～)、製品の世代ごとに異なるプロセスや管理方法が存在することも多い。そのため、設計ノウハウが暗黙化され業務の属人化を招くケースが比較的多い。


以上の状況に対し、生成AI(中でも大規模言語モデル(LLM))は、「大量の自然言語情報を処理する能力」「マルチモーダルデータの処理能力」「従来AIをはるかに超える文脈の推論力」を持つために、上記のデータ特性を有する製造業の設計開発業務において、従来のボトルネックを解決し得る技術である。生成AIには、視覚情報、数値情報、テキスト情報など、異なるモーダルを持つデータを組み合わせる新たな知見を引き出す可能性がある。特に、非構造化データや膨大なテキストデータからパターンを見つけ出し、設計者にとって有用な情報を提供できる可能性がある。

3) 生成AIの限界とテーマ選定の重要性

しかし、いくら高い推論力を持つ生成AIにおいても、上記2)節で述べたような課題が絡み合うと業務への適用が難しくなる。また、上記④のようにそもそも暗黙知がデータとなっていない場合は、暗黙知を知らない人間が暗黙知を必要とする業務をこなせないことと同様に、AIでも解決することはできない。そのため、生成AIの価値や効果を高めるために生成AIが生きる領域(業務プロセス・データ)の見極めと検証が極めて重要になる。

製造業×設計開発の領域は個別性が高い業務が多く、元来システム化の障壁が高かった。その分、生成AIシステムの活用余地が大きな領域の一つと捉えられている。そのため生成AI導入の機運は高まっているが、現場に業務のシステム化のノウハウがたまっておらず、基本的なハウツーから学んでいく必

図表 1 製造業の設計開発業務の特徴



要があるものと推察する。そのため、本稿では実例に基づいて領域の見定めから概念実証（PoC）、本番に至るまでの一連のプロセスを棚卸しする。したがって、本稿は IT システムに関する高度な専門知識を有する方々というよりも、生成 AI の登場を契機にデジタル化に取り組み始めた現場の方々を対象として、ガイドラインの役割を果たすことを目的としている。

2 一般的な生成 AI の業務適用への進め方

1) 一般的な AI 導入に向けた検証プロセス

AI 技術を業務に適用する際には対象テーマ選定、技術検証、PoC、本番導入の 4 段階で進めることが一般的である。まず、AI をどの社内・顧客業務に適用するか「テーマ選定」を行い、一部のデータを用いて想定テーマに対する AI 適用が可能かどうか「技術検証」を実施する。次段階として検証した機能をモックアップ^{※2}的に業務の一部（利用者、業務領域）に適用し、その効果を「PoC」にて確認する。PoC を通して投資対効果が得られると判断した

場合、正式なシステム開発を行い「本番導入」していくという流れである。こと生成 AI の導入に関しても同様のプロセスを踏みながら活用を進めていくことが望まれる。

2) 自社データを活用した生成 AI 活用のキーポイント


では、上記の検証プロセスにのっとり、自社内のデータを活用しながら生成 AI 活用の成果を出していくためにはどのような観点に留意する必要があるだろうか。筆者らは生成 AI が価値を発揮するキーポイントとして「詳細な業務理解」「最適な技術適用」「適切なユーザーインターフェース (UI) / ユーザーエクスペリエンス (UX)」の三つを挙げる。

① 詳細な業務理解

生成 AI を活用する想定業務プロセスを形式知化し、どの業務が全体の中でボトルネックになって

※2 技術検証等を目的に一部の機能やデザインを簡略化して作成された、実際に動くシステム・アプリケーション

図表 2 自社データを活用した生成 AI 活用のキーポイント



出所) NRI 作成

いるのかを把握し、生成 AI 活用方法を具体化する。同時にそれぞれのプロセスで利用するデータ、人間の判断が必須のプロセス（ヒューマンインザループ設計^{※3}）はどこかを棚卸しすることで、生成 AI 適用可否の判断材料をそろえる。

② 最適な技術適用

生成 AI を適用する業務プロセスを明確にした上で、自社データを利用して生成 AI に回答を生成させる、自社の既存システムに対して必要な情報を生成 AI に入力させる等、どのような機能を担わせる必要があるのかを見極める。その上でそれぞれの処理に対して適用すべき生成 AI モデルおよびロジックを検討する。また、その過程で生成 AI が解釈しやすいように自社データの情報整備を実施する。

③ 適切な UI / UX

生成 AI を適用する業務プロセスの中でユーザーにとって違和感がなく情報の入力、出力を得られる UI を構築する。特に入力情報としてもユーザーの能力に依存せず、同じ情報粒度で入力が可能な UX

を確立する。

生成 AI を活用する手段先行の場合当たり的な取り組みではなく、上記三つのポイントに留意をした適用先の見極め、検証プロセスの設計、推進が生成 AI にて成果を実現するための要点であると考ええる。

3) 生成 AI 導入に求められるスピード感

前述した検証プロセス、キーポイントを踏まえて生成 AI の導入を進めることに加え、従来型の AI 導入よりも実施のスピード感が重要になるという点も指摘しておきたい。その理由として生成 AI 技術進歩の速さがある。OpenAI 社の「OpenAI o1」では人間の思考過程を再現し、論理的思考、計算能力等の能力において従来型の「GPT-4o」と比較して圧倒的な差を示しているが、「GPT-4o」がリリースされてから人間の思考を反映した「OpenAI o1」がリリースされるまではわずか 4 カ月である。その

※ 3 AI 等による自動化・自律化システムにおいて、一部の判断や制御にあえて人間を介在させる設計

他スケーリング則に沿った従来型の LLM 発展とは別軸にて Sakana AI 社のように複数の最新ではない LLM を組み合わせたエージェント^{※4}が論文執筆のような複雑なタスクをこなす事例^{※5}も次々と出てきており、昨日まで実現が困難であった技術的課題が今日、明日にできるようになると言っても過言ではない。

このような環境下では、生成 AI 導入のインパクトが大きい業務の中でも特に実効性が高い業務をしっかりと見極め、できる限り早く業務に適用し、効果を得ていくことが重要である。極端な例ではあるが、検討に時間を要している間に技術革新により推し進めていた検討方針と異なるアプローチが有効となり、初期検討から見直しが必要となることで、市場の変化についていけず、競争力を失うリスクも考えられる。

3 製造業における生成 AI 活用の留意点

本章では、前述した製造業の特徴を考慮した上で、スムーズかつスピード感を持って生成 AI 活用を進めるためにどのような点に留意すべきかについて述べる。製造業においては目下「社内業務効率化」に向けた生成 AI の活用が優先されるが、業務効率化のインパクトを基に選定したテーマは、往々にして前述した設計開発業務で取り扱うデータの量・質の観点から技術的な実現難易度が高いものとなる。そのため、適切に技術的な実現性の高い検討テーマを選定する、もしくは難易度の高いテーマに取り組む際にも対象テーマの業務プロセスを分解し、実現性の高い領域を優先して実装、本番導入につなげることでスモールかつクイックに効果を出していくことが望まれる。

1) 適切な検証テーマ選定・MVP での本番導入


生成 AI の導入テーマを選定した際に、往々にして「生成 AI を利用する」という手段が先行し、詳細な業務理解やデータ理解を実施しないまま手を動かし始めて技術検証を開始してしまうケースが多い。迅速に現場に導入し、ユーザーに利用してもらうことを目指すのであれば、詳細な業務・データ理解にこそ時間をかけるべきであると筆者らは提言する。特に製造業においては、前述した設計開発業務で取り扱うデータの量・質の観点から、この観点の見極めがより一層重要になってくる。

生成 AI の活用による課題解決が実現した際の時間削減インパクトから検証対象テーマを選定していくが、テーマが決まった段階で対象の業務を熟知した業務部門の担当者を巻き込み、詳細なヒアリングを重ねることで業務フローを「誰」が「どのデータ」を使って「どのように」業務を実施しているのかを形式知化する。すでに既存業務の流れが一定社内内の基準として資料化されていれば、それらを利用しつつ詳細情報を追加していくことが推奨されるが、製造業の設計工程などはその業務の複雑性から属人化された暗黙知のルールで業務が回っていることが大いにあり得る。そのため、この業務・データフローの整理が鬼門となり得るが、しっかりと形式知化することを推奨する。対象テーマの業務部門の担当者も認識相違のないレベルまで形式知化できれば、ど

※4 人とデータや AI システムとの対話の仲介者（エージェント）となり、詳細な指示なく、目標に向けて状況を理解し、最適な行動をする生成 AI を利用した自律型システムの総称

※5 Sakana AI 社の「The AI Scientist」では生成 AI が人間の介入をほぼ必要とせず、自律的に科学研究のプロセスを実行する <https://sakana.ai/ai-scientist/>

図表3 業務プロセス棚卸し・ボトルネック把握のイメージ



出所) NRI 作成

こを生成 AI に担わせることが最も効果的か、人間の作業でも負担はない部分はどこか、またそこで利用するデータは扱いやすいものか、判断材料が明確に出そう。その結果として実現性が高く、効果が見込まれる適切な検証テーマを選定でき、生成 AI の検証・ユーザーへの導入がスムーズに進む可能性が高まる。

加えて、生成 AI の活用検証において重要なのは、どこまで技術検証を突き詰めるのかを早期に見極め、必要に応じて検証を中断する判断軸を持つことである。従来型の AI 活用においては、取り組みに見合う効果が期待されるのであれば、時間をかけて精度改善に取り組むことに価値があった。しかし生成 AI においては、前述したような技術進歩の速さから、技術的ハードルは時間が解決してくれる可能性が高く「技術進化を待つ」ことも有力なオプションとなり得る。一度やり始めたことには思いが乗って続けたい心理が湧くが、それらを抑え、検討の軸足を移しつつスピード感を持って検証を進めていくことが推奨される。


上記の方針で検証を進めるため、筆者らが提案するのは、前述したような業務・データの理解が十分

になされている前提とはなるが、実施優先度の高い対象テーマ（大テーマ）の機能要素を細分化（小テーマ）し、実現可能性の高い機能要素に対する「技術検証→PoC→本番導入」を優先して実施し、早期にユーザーに使ってもらうことでスモール・クイックに MVP^{※6}で効果を出していく手法である。機能ごとにどのような生成 AI 技術が必要なのか、また利用データの活用難易度はどの程度かを棚卸しし、実現可能性が高いと思われる機能の実施検討を進める。検討を進める中で技術的ハードルが立ちはだかった際には、その機能の検証をどこまで追求するのか基準を設け、それらを達成できない場合は別の機能要素の実現に検討軸を移すようなフットワークの軽さが求められる。基準には検証コスト・期間に上限を定めるというプロセス整備、目標となる技術的重要業績評価指標（KPI）に達するかどうか等の指標を設けるケースが多い。

技術的な難易度が高い機能や基準未達で頓挫した

※ 6 MVP (Minimum Viable Product) とは、最小限の機能を持つ初期バージョンのプロダクトのこと

図表 4 生成 AI 活用テーマの推進フロー



出所) NRI 作成

小テーマもそのまま放置せず、「何が課題で、何が技術的に改善されれば実現し得るのか」を明確にしておくことが重要である。そうすることで、生成 AI 技術の発展に目を光らせておけば、ふとしたタイミングで実現難易度が下がり、実現に向けた道が開けるケースもある。

2) 非構造化データの変換／マルチモーダルモデルの利用


製造業における非構造化データ（図面、ロジック図、フローチャート、CAD データなど）を扱う業務は、従来型の AI では取り扱いのハードルが高く、業務の変革が困難であった領域といえる。そこに対して生成 AI で対処できる可能性が出てきたのは前述した通りである。しかしながら、生成 AI で全てを適切に処理し活用できるわけではない。生成 AI が認識し、活用しやすい形に情報を変換する、つまり良質なデータをいかに整備するかが重要となる。そのために「どのような業務を生成 AI で代替したいのか」を明確にし、既存のデータを「生成 AI でどのように前処理を実施するか」を検討する必要がある。

広義の意味での生成 AI 活用にはさまざまな手法があるが、生成 AI を活用して膨大な社内データから自身の目的に沿う資料を取得し、対応方法を検討させる、いわゆる検索拡張生成（RAG）に対する業務適用を図る方法は、業務効率化を目指す上でのテーマとして初手に挙がる手法である。本節では、RAG で既存業務を代替するという前提のもと、非構造化データの前処理で効果が見込める手法を以下に述べる。

(1) マルチモーダルな生成 AI モデルを利用した図表の文章化

複雑な図表や設計書は、もともと文字を極力少なくし、その表現で意味を認識させるものである。しかし、RAG 適用において文章を検索する際には、文章同士の類似度から関連度を測ることが一般的であるため、情報量を増やす必要がある。そのための前処理として、図表や設計書の画像などを認識し、回答が可能なマルチモーダルな生成 AI で文章情報を作成することを推奨する。どのように図表や設計書情報を文字に変換させるか、生成 AI への指示を工夫することで、実施したい業務に適した文章の出

図表 5 生成 AI が解釈しやすいデータ変換方法



注) Anthropic 社「Claude」、Google 社「Gemini」、OpenAI 社「GPT-4/4o」などが代表的な画像等を扱えるマルチモーダルなモデルとして挙げられる
出所) NRI 作成

力となるように工夫するプロンプトエンジニアリングも重要である。

(2) 生成 AI が認識しやすいデータ構造への変換

複雑な図表やフローチャートを生成 AI に解釈させ、適切な回答を得るためには、その構造を生成 AI が認識できるように情報を変換することが求められる。一般的には Markdown 形式^{※7}に情報を変換することで生成 AI は解釈しやすいとされているが、Markdown 形式だけでは表現に制限が出てくる。生成 AI の認識精度の向上が図れるその他のデータ表現手法として、HTML 形式^{※8}、JSON 形式^{※9}、Mermaid 記法^{※10}などを利用し、複雑な図表の表現の幅を広げることも推奨する。全ての既存の図表を人間が手で変換するのではなく、データ準備にもマルチモーダルな生成 AI モデルを利用し、データ変換させることで前処理の効率化も図れる。

3) 生成 AI 検証クラウド基盤の構築

前述したように製造業はソフト・ハード両面を扱う業種の特性上、他業界と比較してプロジェクトライフサイクルが長いと、トライアンドエラーを早

期に実施し、改善策を実行する手法論とは必ずしも親和性が高くない。そのため、生成 AI 導入に対しても慎重な設計から入る傾向があるが、生成 AI の活用において重要なのはスモール・クイックに成果を出していくことである。

特に生成 AI 活用が従来型の AI 活用と大きく異なるのは、精度・効果検証の基準を定量化することが難しい点である。実際に利用した上で、レスポンス速度、回答の揺らぎ、根拠のない回答（ハルシネーション）の度合い等がどこまで業務上許容されるか、ユーザーの定性的な所感・評価が重要となる。そのため、早期にユーザーにトライしてもらい、フィードバックを得ることが業務適用プロセスをスムーズ

※7 ウェブ上でのドキュメント作成に利用される軽量マークアップ言語

※8 ウェブページの構造を定義する言語で、テキストや画像、リンクなどのウェブコンテンツをブラウザで表示可能

※9 データ交換用の軽量フォーマットで、設定ファイルや API レスポンスなど、ウェブ開発の多くの場面で利用される形式
※10 テキストを基に図表を生成するツールで、複雑な図も簡単なコードで表現可能

に進めるために重要である。

技術検証段階でのモックアップなどを個人の端末のみで開発し、それらをユーザーに画面共有しながら意見を得ることはできても、実際に使って感想をもらうことは難しい。そこで対処手法として、開発・検証用の簡易的なパブリッククラウド基盤（Azure、AWS、GCP など）を構築することを筆者らは推奨する。

自社クラウド開発におけるセキュリティルールにのっとりた上で、クラウド基盤を立ち上げ、そこで技術検証の段階から一部の対象ユーザーに利用できる検証環境（サンドボックス環境）を整備する。そうすることで、ユーザーから本質的な改善に向けたフィードバックの示唆を得ることができる上、技術検証から PoC に進めた際の認識のズレが少なくなり、全体としてのテーマ推進の成功率が向上する。また、付随的な効果として、各種クラウドサービスにおいても生成 AI 活用の機能に特化したリソースが強化されているため、スクラッチ開発よりも効率的に実装を進めることも可能である。

一方、機密性の高いデータを扱う場合、クラウド基盤で生成 AI を利用するのがセキュリティルールの観点から困難であるケースが存在する。ここに対する打ち手として、「Llama3」や「Mistral」といったオープンソースモデルを活用できるオンプレミス^{※11}な生成 AI サンドボックス基盤を確立することも一手である^{※12}。

4 具体的な生成 AI 活用推進事例

本章では、製造業の生成 AI 活用プロジェクトにおいて、3 章で述べた留意点に対し NRI がどのような対策を実施しているかを提示する。なお、以降は NRI がコンサルティングプロジェクトとして推進し

たプロセスであるが、社内で生成 AI 活用を推進する場合でも同様のプロセスを取ることを推奨する。

1) 検証テーマの選定と技術検証の見極め基準

(1) 検証テーマの選定

検証テーマを適切に選定するためには、3 章 1) 節で述べたような業務・データ面の詳細な把握が必要である。一方、最初から全てのテーマ案に対し詳細な把握をすることは現実的に困難である。そこで下記のように、業務内容をデータの判断基準に対しマッピングし、どの検証テーマであれば限られた期間で有用な検証が行えるかの判断を実施している。

①まずは検証テーマの業務内容について現場担当者に簡易なヒアリングを実施し、概要を把握する。このとき、併せてデータの量や複雑度についても率直に意見をもらい、以降のデータ軸に対するマッピングの判断要素とする。

②次に、各検証テーマをデータに関する二つの評価軸の上にマッピングする。一つ目の評価軸は「データ活用の難易度」である。この軸では、1 章 2) 節で述べたデータ品質の観点に沿って社内データの確認を行い、データ課題の大きさを 3 段階で評価する。二つ目の評価軸は「活用技術の展開可能性」である。3 章 1) 節で述べたように、生成 AI の検証では他テーマにピボットすべき場面も十分に考えられる。その中で、中断した検証テーマで得た知見を他テーマで

※11 物理的なサーバーなどの設備を社内やデータセンターに構築し、運用すること

※12 NRI は機密・機微情報を安全に扱え、個別企業の業務に合わせてカスタマイズが可能な「プライベート LLM」を提供している https://www.nri.com/jp/news/newsrelease/1st/2024/cc/0111_2

も横展開・活用することができれば、自社の生成 AI 活用を加速度的に推進していくことが可能になる。したがって、検証テーマに特化型 AI やニッチな技術が必要でないかどうか判断し、それらを除く横展開可能な技術で対応できる検証テーマを高評価としている。

③最後に、②のように評価した各検証テーマの中から「データ活用の難易度」が現実的であり、かつ「活用技術の展開可能性」も高い検証テーマを抽出する。ここまで検証テーマを絞れば、①でヒアリングした内容を改めて確認し、業務改善効果が最も高いものから順に検証するとよい。

(2) 技術検証の見極め基準

昨今、生成 AI エージェントなど革新的なデジタルトランスフォーメーション (DX) 施策を目にする機会が多い。しかしそのような革新的なソリューションは技術的難易度が高く、実装に必要な工数が多い。今回筆者が提言するような、数ある業務課題から生成 AI を活用できる対象を探す段階においては、簡易な技術を用いて検証を行い、実業務へ適用するにはどの程度の工数がかかるかの感覚を見定める必要がある。したがって、既存データの形式は変更せず、既存の生成 AI ライブラリーの基本的な使用方法に沿って一度精度検証を行うことを基本としている。そこから各業務の具体ケースを徐々に検討し、データ形式の変更や AI 処理のカスタマイズなどを検討する。この検討については、実施期間を明確に定めることで「技術的な沼」を回避することができる。

生成 AI は 2 章 3) 節で触れた通り技術的進歩が速いものの、複雑化された業務課題を一瞬でひもとけるような革新的な内容はいまだ現れていない。したがって現在の段階では、新しい AI ニュースが出て

きていても、目標期間内でできることを確かめ切った後、判明した次ステップの工数感と投資可能なリソースを加味し、検証を続けるかどうかの判断を行うことを推奨する。

2) 生成 AI が認識しやすいデータ構造への変換

(1) 図表データの変換

製造業のデータは、どのような社員でも扱えるような Excel や Word などの Office 形式であることが多く、またその中身も複雑な業務やシステムを表現するための図や表が多用されている。そのようなデータはそのまま生成 AI に読み込ませるのではなく、生成 AI (特に LLM) が得意とする言語データに変換する。3 章 2) 節で紹介したマルチモーダルな生成 AI も一手ではあるが、現状の技術レベルでは複雑な図表に対し柔軟かつ正確にデータを解釈させることは難しい。そのため現時点では、Office 形式のデータは PDF に変換し、各種 OCR ライブラリーを用いてプログラムに読み込ませることを推奨する。

OCR ライブラリーを用いることの利点として、一般的な OCR ライブラリーであれば、ライブラリーの機能で「このデータは表である」というラベル付けを行った状態で、表データの読み取りができる。読み取ったデータが表形式であるとプログラム上で判別できれば、それを Markdown 形式に変換するなどの加工が柔軟に行える。実際に、OCR で表オブジェクトとして認識させた情報を、疑似的に Markdown 形式に変換させた上で生成 AI に要約させることで、表データを自然な文章データに変換できることを確認している。

(2) 業務データの HTML・Markdown 形式への変換

また Excel や Word など形式化されているデー

タを、そもそものファイル形式から見直しを行い、HTML と Markdown を併用した形式として整備することも、生成 AI をより活用しやすくする方法として挙げられる。ただし現在の業務データの形式を全て置き換えることは工数がかかるため、本稿で述べていたような技術検証の段階で、数サンプルの業務データを HTML・Markdown の形式で置き換えて検証を行うことを推奨する。業務データの形式変換により、①生成 AI の精度がどの程度向上するか、②生成 AI の精度向上がどの程度業務効率化に資するか、の 2 点を判断することで、業務データ形式の整備を行うか否かを判断する。また業務データ形式の変換を行わない場合でも、当検証を通じて業務データのあるべき姿を検討するため、一般的な業務標準化を実施する際の検討材料もそろえることができる。なお、HTML や Markdown 形式に業務データを変換した場合、

- 各社員に共通的な Wiki ページの形式でドキュメント群を保存・閲覧することが可能になる
- Git^{※13}を用いたドキュメントのバージョン管理が可能になる

などの副次効果もある。

3) 生成 AI 検証クラウド基盤の構築

3 章 3) 節で述べたように、検証用のシステム基盤はパブリッククラウド基盤を推奨する。同一パブリッククラウド上に開発環境、アプリケーション動作環境、生成 AI アプリケーションに必要な各種サービス (DB、ウェブサーバーなど) の全てを集約することで、最小限の工数でセキュリティを担保しつつ生成 AI 検証基盤を構築することができる。また一度作成した環境はその内容を簡易に複製することもできるため、本番運用に向けた準備としても非常に効率が良い。実際に PoC を行う際には、一部

の現場担当社員にパブリッククラウド環境のアカウントを割り当て、安全な環境の中、ソリューションのモックアップを初期段階から試用してもらい、率直なフィードバックをクイックに収集する流れとなる。繰り返しとなるが、このように「現場の生の声」を検証の初期段階から集められる環境を整えることは、本稿の主題である「スモールかつクイックな検証」の礎となる。

5 おわりに

生成 AI 活用は「膨大な非構造データ」や「形式知化されていない暗黙知」が蓄積されやすい製造業の設計開発の領域においてブレークスルーをもたらし得る技術であり、ユーザーからの期待値は大きい。

だが、ここまでに述べた通り「目に見える効果を生めそうな魅力的なテーマ」には、往々にして「こつこつと地道なデータ整備が必要な小テーマ」や「必要な技術が成熟途上にある小テーマ」が包含されている。それらのテーマを切り分け、実現可能性やインパクトを見極めていくためには業務とデータの流れを詳細に棚卸しする必要がある。また、ユーザーからのフィードバックによる PDCA サイクルを回しやすい検証基盤をつくることが有効である。日々発展する生成 AI 技術の変化を取り入れられるような“スモール・クイック”な検証テーマのライフサイクルを定義することからぜひ始めてみてほしい。

なじみのない新しい技術で現行業務を変える取り組みにはハードルを感じるかもしれないが、生成 AI

※ 13 ソースコードや変更履歴を管理するための分散型バージョン管理システムの一つ

という新しい道具を使いこなすことが、現場の担当者を属人的で負担の大きい業務や付加価値の低い単純作業から引き離し、より付加価値の高い業務へとシフトしてもらうための助けとなる。本稿がそのような取り組みに挑戦する人の一助となることを願っている。

(監修：大道 亮)

●…… 筆者

平原 一輝 (ひらはら かずき)

株式会社 野村総合研究所

AI コンサルティング部

シニアコンサルタント

専門は、アナリティクス、デジタルマーケティング、アプリケーション開発・導入支援など

E-mail: k-hirahara@nri.co.jp

●…… 筆者

坂上 竜馬 (さかうえ りょうま)

株式会社 野村総合研究所

AI コンサルティング部

シニアコンサルタント

専門は、新規事業戦略策定、DX 伴走支援（製造業）など

E-mail: r-sakaue@nri.co.jp

●…… 筆者

川名 拓己 (かわな たくみ)

株式会社 野村総合研究所

AI コンサルティング部

シニアコンサルタント

専門は、アプリケーション開発、データサイエンス、UX / UI デザインなど

E-mail: t-kawana@nri.co.jp