

生成 AI の業務実装で直面する「思考の再構築」

AI戦略コンサルティング部 コンサルタント 久米 脩平

1 生成 AI の価値発揮領域はどこか

1) 個別業務利用への広がりを見せる生成 AI

ChatGPT の登場を皮切りに、生成 AI は瞬く間にビジネスに浸透し、活用領域を拡大している。初期は情報検索、文章作成効率化、アイデア出しといったチャットボット利用が主流だったが、近年では、特定の業務プロセスや専門ワークフローに組み込まれる形での活用が見られる。例えば、マーケティングにおけるパーソナライズ広告文自動生成、法務における契約書レビューや条項抽出、コールセンターにおける回答草案生成など、各業務特性に応じた具体的なユースケースが生まれている。

この進化は、われわれの業務に大きな変革をもたらす可能性を秘めている。他方、業務プロセスの一部に組み込む形での生成 AI 実装は、チャットボット実装と比べて、概念実証 (PoC) にとどまることが多い。ユーザーからの質問に自由な形式で回答することと、一連の業務プロセスの中で、特定の制約下でタスクを遂行することでは、プロダクトへの要件が大きく異なるため、同じ生成 AI 実装でも一くりに考えることはできない。本稿では「業務プロセスに組み込む生成 AI プロダクト」の実装検討における要諦を、NRI の実際の検討例と共に提言する。

2) 生成 AI の業務導入における本質的価値は「思考の再現」

本節では、これまでのデジタルトランスフォーメーション (DX) の歴史を踏まえ、生成 AI が業務活用において真価を発揮する領域はどこかを見定める。

まず、あらゆる業務は「作業」「判断」「思考」に分けられる。ここでは、人事部社員が従業員の退職を抑止する業務を例に説明する。「作業」の業務では退職リスクが高いと判断された従業員の上長に、状況伺いやフォロー依頼のメールを送信するなどの業務が挙げられる。また、その上流には、各従業員に対して、退職リスクが高いかどうかを判定するという「判断」の業務が存在する。さらにその上流には、どのような人が退職してしまうのか、またどのようにすれば食い止められるのかを考えるという「思考」の業務が存在する。これらの業務は「思考>判断>作業」の順で DX による業務の再現の難易度が高いと整理される。

(1) STEP1 : RPA

2017 年以降、金融機関などでの導入を皮切りに急速に認知された RPA^{※1} は、定型的な入力・転記・集計といったルールベースの繰り返し作業を自動化した。人事部業務の例では「従業員の上長とそのメールアドレスを特定し、定型メールを送信する」といった作業の自動化が挙げられる。

RPA はヒューマンエラーの排除や待ち時間の削減といった点で効果を挙げたが、効率化対象はあくまで人間が定めたルールに従う業務であり、自律的な判断や思考を伴うプロセスには適用できなかった。

※1 Robotic Process Automation (RPA) は、これまで人間のみが対応可能と想定されていた作業、もしくはより高度な作業を、人間に代わって実施できるルールエンジンや AI、機械学習等を含む認知技術を活用して代行・代替する取り組み。出所) 日本 RPA 協会

図表 1 業務の分解と DX 化のステップ (例: 人事部の従業員退職抑止業務)

DX化のステップ	STEP1:「作業」の業務	STEP2:「判断」の業務	STEP3:「思考」の業務
実際の業務例	<ul style="list-style-type: none"> 退職リスクが高いと判断された従業員の上長に、状況伺いやフォロー依頼のメールを送信する 	<ul style="list-style-type: none"> 各従業員に対して、退職リスクが高いかどうかを判定する 	<ul style="list-style-type: none"> どのような人が退職してしまうのか、またどのようにすれば食い止められるか考える
最適なDX手法とできること	RPA 従業員の上長とメールアドレスを特定し定型文を自動送信する	従来型AI(分類・予測) 過去のアンケートと退職者リストをもとに退職の可能性が高い従業員を予測する	生成AI 直近のアンケートや面談記録をもとに、退職を食い止めるための個別アプローチ方法を生成する

出所) NRI 作成

(2) STEP2 : 従来型 AI

機械学習を中心とした AI (ここでは、生成 AI との区別の意味で「従来型 AI」と呼称する) は、大量の過去データから相関関係の発現パターンを学習する。需要予測モデルやレコメンドエンジンが典型例であり「晴れの日ほど売り上げが上がる」「年齢が高い人ほど商品を購入しやすい」といった、ある事象や状態と目的変数の関係性を推定できる。ここで重要なのは、推定するのは「相関」であり「因果」ではないという点である。従来型 AI は、ある事象や状態の目的変数への作用を、厳密なロジックやルールを規定せず「曖昧さ」を許容しながら予測する。これは人間の判断に近く「こういうときはこうするとうまくいく」といった業務における経験則にもとづく判断のようである。人事部業務の例では、過去の退職者データと、その社員が退職前に回答したアンケート結果などを用いて、将来退職の可能性が高い社員の予測などが行える。しかし、従来型 AI の判断は良くも悪くも「曖昧さ」が残る。退職の可能性が高いと判断された理由はブラックボックスであり、結果の解釈や、背景事情を考慮した業務上の行動選択などの「思考」は依然として人間が行っていた。

(3) STEP3 : 生成 AI (Generative AI)

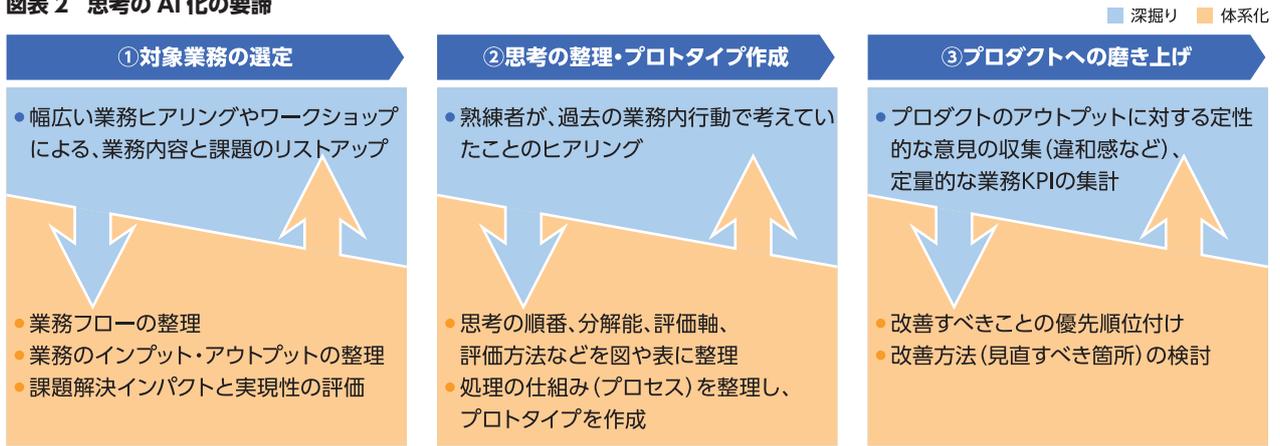
生成 AI の登場は、残された「思考」業務を再現

する可能性を秘めている。生成 AI は、学習したデータにもとづいて新たなコンテンツ (テキスト、画像、音声など) を「生成」する能力を持つと同時に、インプットデータの多様さも許容される。これにより、従来型 AI が苦手としていた、人間が行っていた「思考プロセス」そのものの効率化・高度化の余地が出てきた。人事業務の例では「アンケート結果や面談記録データをもとに、退職を食い止めるための個別アプローチを生成する」などが可能である。これは、単なる情報処理の自動化を超え、人間の「思考」そのものを AI が再現し、拡張する (以降、「思考の AI 化」と呼称する) 領域に踏み込んだことを意味する。

2 思考の AI 化の要諦 : 三つの「深掘りと体系化の行き来」

生成 AI の本質的な価値は「思考の AI 化」であるとした場合、われわれはどのようにそれを実現すべきだろうか。この手の話題では、よく「暗黙知の形式知化」という聞こえのよい言葉がうたわれるが、その「形式知化」の具体的手法は紹介されないことが多い。本章では、NRI が自社ならびに顧客向けに生成 AI の業務実装を推進する中で見えてきた「思考を AI 化したプロダクトを作るためのアプローチ」を紹介する。なお、本整理における「生成 AI」は大規模言語モデル (LLM) を対象とし、プロダクト設計・

図表 2 思考の AI 化の要諦



出所) NRI 作成

開発に焦点を当てるため、プロダクトの浸透などは含まない。

1) 要諦の全体像

思考を AI 化したプロダクトを作るには、図表 2 に表現した通り「①対象業務の選定→②思考の整理・プロトタイプ作成→③プロダクトへの磨き上げ」の三つのステップが必要である。また、各段階において「深掘りと体系化を行き来」するような行動が求められる。

2) ①「対象業務の選定」における深掘りと体系化

このステップの目的は、生成 AI で効率化・高度化すべき業務を適切に選ぶことである。まずは、既存業務がどう回っているか、どのような課題があるか棚卸しする。具体的には、若手やベテランを問わない業務従事者へのヒアリングや、ワークショップでの洗い出しが有効だ。課題の洗い出しにおいては、組織の存在意義(ミッション)や、ステークホルダーからの期待といった前提情報を整理してから行うことで、顕在課題だけではなく、潜在課題・将来課題まで考えたい。

次に、ヒアリングやワークショップで得られた具体的な情報をもとに、業務フローを書き起こす。また、業務フローの中に位置する個々の業務は、どの

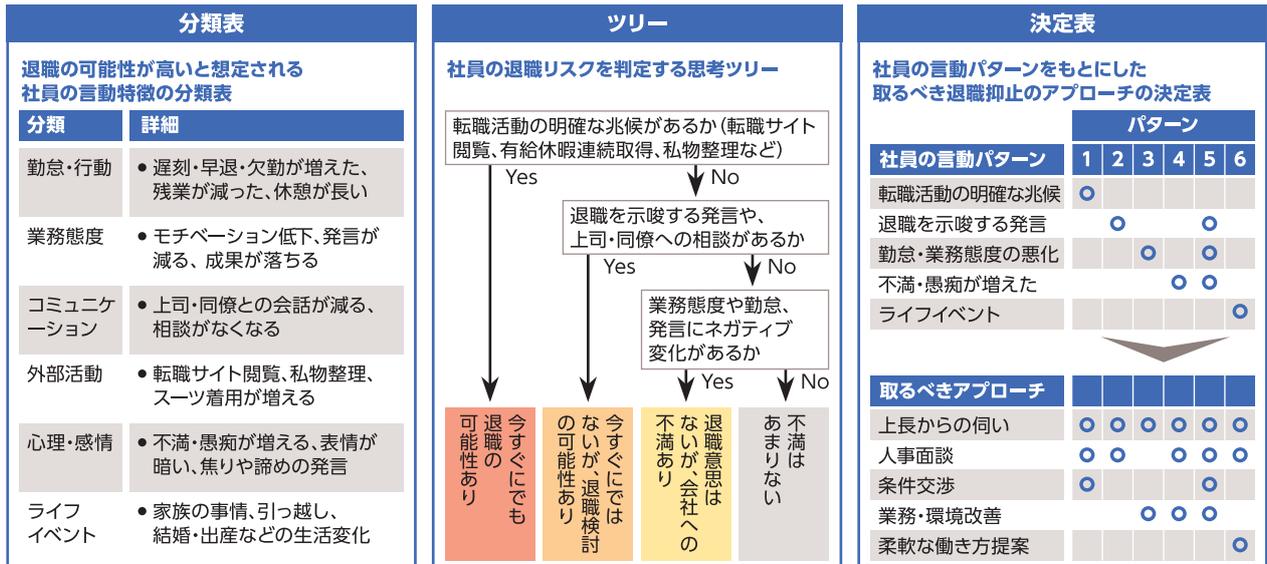
ようなインプットをもとに、何がアウトプットされるのか、さらにはアウトプットが次の業務にどのようにインプットされるのかを整理しておくことで、後工程で生成 AI によるサポートを検討する際に、必要なデータや、成果物が満たすべき要件が分かりやすい。

業務の流れと個々の業務の詳細が分かれば、生成 AI でサポートすべき領域を特定する。各業務を「課題解決のインパクト」と「実現可能性」の 2 軸で評価していくアプローチが有効だ。業務が細かく整理されていれば、インパクトは「削減される工数」「優先度の高さ」に、実現可能性は「技術面」「アセット面」「コスト面」などに分解して評価でき、プロダクトに期待されることや、乗り越えるべき障壁が明確になる。

3) ②「思考の整理・プロトタイプ作成」における深掘りと体系化

対象業務が定まれば、業務従事者がどのような思考をしているか、言葉や図表にしていく。具体的な手法としては、ベテランや実績のある人(以下「熟練者」と呼称する)へのヒアリングが不可欠だ。この際に意識すべきは「熟練者の思考の一挙手一投足を分解する」ことである。熟練者の中には、輝かしい成果を残しつつも、自身の思考が構造的に整理され

図表3 思考を構造的に整理する手法の例



出所) NRI 作成

ていない人も少なくない。そのため、単に「どのように考えていますか？」と尋ねたり、作りかけの図表を見せながら「この整理のどこに違和感がありますか？」と尋ねたりすると、意見が出てこないことも多い。そこで、過去の業務内の行動を具体的に想起してもらったり、可能であれば業務内の行動を録画させてもらい、一緒に振り返ったりして、意思決定や行動の瞬間に何を考えていたか、どの順番で考えていたか、どのような分岐が頭にあったかを細かく聞いていく。泥臭い手法ではあるが、ここで熟練者の考えを丁寧に言葉にする（思考を解きほぐ）ことが重要だ。

細かい情報が大量に集まってきたら、それらを構造的に整理し、プロダクトに落とし込みやすい形にしていく。例えば、図表3のような、分類表やツリー、決定表などの整理の仕方がある。図表は人事部の退職抑止業務を例に記載しており、本来はここまで単純ではないが、イメージアップのために情報量を落としている。ここでは、思考が漏れなくだぶりなく整理されているかどうかを意識すべきであり、この意識を持つことで、既存業務でおろそかになっている観点が偶発的に明らかになることもある。

また、ここまで思考が整理できると、おのずとプ

ロダクトとしての大まかな実装方針が見えてくる。

①「対象業務の選定」で整理した、その業務に必要な情報・データ（インプット）と、その業務の完了時に求められる成果物要件（アウトプット）を満たすことを意識しながら、両者をつなぐ処理の仕組み（プロセス）のつくり方を検討し、プロトタイプを作成する。具体的な作業としては、アーキテクチャーやプロンプトの設計などが挙げられる。ここで注意したいことは、思考の一部が機械的なルールとして整理できている場合や、インプットとアウトプットが定型化している処理がある場合は、必ずしも生成AIを用いる必要はないということである。生成AIは、非定型情報を扱う場合や、大まかなロジックに加えて、細かい文脈理解を伴う思考の再現にこそ真価を発揮するため、プロダクトの中での、生成AIとルールベース処理の使い分けが肝要である。

4) 補論：「思考の整理」は人間がやるべきことなのか

ここで「思考の整理も生成AIにやらせればよいのではないか？」という問いを持つ人もいるだろう。実際に、思考や推論に特化した大規模推論モデル(LRM)が台頭しており、代表例として、OpenAI

社が2024年12月に公開した「o1」をはじめとした「oシリーズ」のモデルが挙げられる。これらのモデルには、CoT（Chain-of-Thought:思考の連鎖）と呼ばれる、複雑なタスクを与えられた際に、解決に向けたステップを論理的に区切ることで、人間のような推論プロセスをシミュレートする機能が具備されている。しかし、筆者は以下の2点の理由から、人間による思考の言語化・構造化への需要は依然としてなくなると推察する。

(1) 「自律性」を容認できない

第一に、企業の責任問題が挙げられる。生成AIが自律的に思考を言語化した場合、その思考プロセスや判断基準の透明性が低く、誤りがあった場合の責任の所在が不明確になる。特に、企業の根幹に関わる業務や、顧客への影響が大きい業務においては、一定の信頼や妥当性がある思考プロセスが求められる。

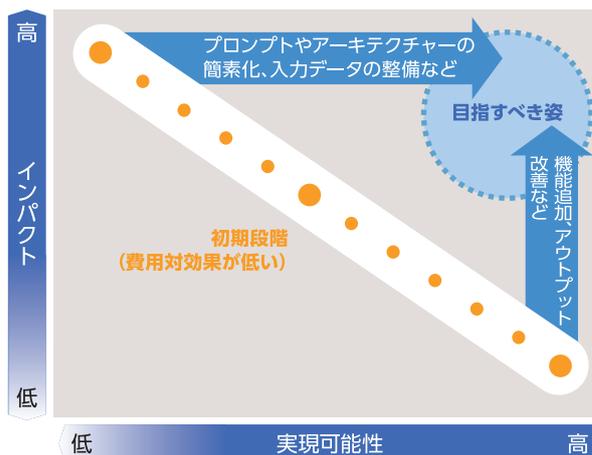
(2) 推論性能にも限界がある

第二に、依然として思考を言語化したプロンプトを与えたほうが、出力の正確性が高い点だ。生成AIは膨大なデータからパターンを学習するが、特定の業務における深い洞察や、暗黙のルール、微妙なニュアンスを完全に捉えることは難しい。実際に、情報量が多い場合や解くべき課題の複雑性が高い場合は推論能力が低下するという研究結果も散見される。人間が丁寧に言語化し、構造化した思考プロセスは、生成AIがより正確で質の高いアウトプットを生成するための、極めて重要な「教師データ」になるといえる。

5) ③「プロダクトへの磨き上げ」における深掘りと体系化

ある程度のプロダクトが完成したら、PoCを実施する。初期プロダクトは完璧ではないことを前提とし、実際の業務環境で利用してもらい、フィードバックを集める。ここでは、定性・定量の両面でプロダ

図表4 生成AIプロダクトを改修する際のイメージ



出所) NRI 作成

クトを評価することが重要だ。定性的な意見（ユーザーの生の声）は、プロダクトの改修ポイントを明確にする。他方、「プロダクトによって業務が効率化・高度化されているかどうか」という問いへの説明力は、事前に設定した重要業績評価指標（KPI）の変化などの定量データのほうが高い。

そして、ユーザーからの意見は、そのまますべて改修要件として取り込むのではなく「改修効果の見積もり」と「改修工数・難易度の見積もり」を行い、優先順位をつけて取り組むべきだ。前者は、ユーザーからの意見が「違和感の指摘」であれば、その違和感が業務においてどの程度クリティカルか判断し、意見が「機能追加の要望」のようなものであれば、その追加機能でプロダクトの価値をどれほど高められるか判断する。後者は、具体的にプロダクトのどこを改修する必要があるか（プロンプト、アーキテクチャー、入力データ、出力形式など）や、改修に必要な時間・スキルを判断する。

筆者は、生成AIプロダクトにおいて、業務へのインパクトと実現可能性はトレードオフになりがちであり、目指すべきは、両者が一定程度高い水準にある状態と考える（図表4）。そのため、プロダクトを改修する際は、実現可能性を担保しつつ、機能追加やアウトプット改善を行ったり、インパクトを維持しつつ、より簡素なプロンプトやアーキテク

図表 5 CAITO の企画書生成機能開発における検討イメージ

①対象業務の選定					②思考の言語化・構造化	
企画書に含まれる資料		掲載数の多さ	フォーマット化のしやすさ	言語化のしやすさ	資料に含まれる要素	記載内容
0	表紙	○	○	○	専門性の高さ	<ul style="list-style-type: none"> • 業界や技術への知見 • 方法論やフレームワーク
1	背景・目的	○	○	○	過去実績の豊富さ	<ul style="list-style-type: none"> • 定量・定性での成果 • 第三者の評価・受賞歴
2	主要論点・仮説	○	△	△	クライアント理解	<ul style="list-style-type: none"> • 企業文化・価値観の理解
3	案件の位置づけ・スコープ	△	△	×	要素A (現在は不足している)	<ul style="list-style-type: none"> • XX • XX
4	NRIの強み	○	○	○	—	—
5	タスク構成	○	○	×	—	—
6	スケジュール	△	○	×	—	—
—	—	—	—	—	—	—
—	—	—	—	—	—	—

出所) NRI 作成

チャーへの変更・入力データの整備を行ったりすることが求められる。実施する改修が、図表 4 上で、どのようなポジションの変化を起こすためのものかを意識しながら優先順位をつけていきたい。

3 実際のケースによるイメージアップ

本章では、第 2 章で述べた思考の AI 化の要諦の裏付け、および具体的な進め方のイメージアップを目的として、NRI の取り組み事例を紹介する。

1) 事例①：NRI のコンサルタント向け生成 AI ツール「CAITO」における企画書生成機能の開発

本節では、2025 年 1 月（藤中・坂 [2025]）^{※ 2} に紹介した、NRI のコンサルタントが業務で利用している生成 AI ツール「CAITO」^{※ 3} において、企画書の一部の草案を生成する機能を実装した際の検討事例を用いて、第 2 章の要諦における「①対象業務の選定」「②思考の整理・プロトタイプ作成」の進め方を解説する。本検討の目的は、NRI が顧客に案件を提案する際に作成する企画書の検討を支援することである。

まず、対象業務選定のために、さまざまな部署や案件タイプを網羅できるほどの大量の企画書を集めるところからスタートした。そのうえで、それらの

企画書に含まれる資料（ページごとの要素）を整理し、各資料について、生成 AI で草案を生成することの価値の大きさと実現可能性を整理した。ここでは、価値の大きさは「当該資料が掲載されている企画書の多さ」と読み替え、実現可能性は「フォーマット化しやすいか」「資料の作り方を言語化できそうか」の二つに分解したうえで、評価を付け、優先的に生成 AI で草案を作成すべき資料を特定した（図表 5 ①）。

続いて、生成 AI にどのように資料を生成させるかを考えるために、記載される内容を構造的に整理した。例えば、「NRI の強み」という資料の内容は、専門性の高さ、過去実績の豊富さ、クライアント理解などの要素に分解し、コンサルタントが、顧客からの提案依頼書（RFP）をもとに、NRI に期待されていることを読み取ったうえで、最適な要素を選んで記載するという思考を言語化した。さらに、整理をする中で NRI が強みとして提示できていない要素もあぶりだされ、既存業務のあり方を問い直すような示唆も得られた（図表 5 ②）。

※ 2 藤中峻・坂拓弥「生成 AI ×ナレッジマネジメントにおける三つのジレンマとその実態」NRI マネジメントレビュー 2025 年 1 月号

※ 3 「Consulting AI Tool」の略称。高い情報セキュリティを担保しつつ、コンサルタントの論文や講演資料をはじめとした多数のナレッジを参照可能なプラットフォームのこと

図表 6 プロダクト改修の優先順位付けのための評価観点

		改修の必要性の高さの評価				改修コストの低さの評価	
必要性	高	間違っている	事実誤認	低	コスト	プロダクト単体の改修	プロンプトの修正・調整
			論理の矛盾				設定・パラメーターの調整
			文法・用語の誤用				コード・システム構成の修正
	違和感がある	一般常識との乖離(かいり)	生成AIモデルの再学習				
		文脈不一致	API ^注 ・インターフェースの見直し				
		日本語として不自然	他プロダクトやシステムに波及する改修				
	低	分かりづらい	曖昧な表現・説明不足	インプットデータの見直し			
			過度に冗長・簡潔				

注) API とは Application Programming Interface の略称であり、ソフトウェア同士が互いに情報をやりとりするために使用するインターフェースを指す
出所) NRI 作成

2) 事例②：生成 AI による B to C 営業改革 (A 社)

NRI がコンサルティング支援をした、A 社の事例を紹介する。本事例では、B to C 営業業務において、生成 AI を用いて、顧客データから最適なアプローチ方法を自然言語で指南するプロダクトを作成した。本節では、この事例を用いて第 2 章の要諦における「③プロダクトへの磨き上げ」の進め方の例を解説する。

本事例では、熟練の営業員の思考を言語化・構造化し、初期プロダクトを開発した後、約半年間で「検証と改修」のサイクルを 3 回実施している。1、2 回目のサイクルでは、0.5 カ月で生成文に対する所感のヒアリングと、出てきた意見をもとにした改修事項の整理を行い、1 カ月でプロダクトの改修を行った。3 回目のサイクルでは、実際に現場で 2 カ月間の PoC を実施し、定性的な意見に加えて、プロダクト導入前後での面談数や成約数といった定量的な指標による効果検証も行った。その後、PoC で得られた意見をもとに 1 カ月の改修（微調整）を行い、本番実装へと進んだ。

また、プロダクトの改修においては、ユーザーから指摘された問題を、改修の必要性の高さで段階分けして整理した。同時に、各問題に対応するための方針も整理し、改修コストの低さと比較しながら、優先順位をつけて改修に取り組んだ。具体的には、

図表 6 のような観点を設けて、指摘と対応方針がどこに位置づくか議論した。このような整理をすると、プロダクト単体の改修では解決できない問題が見つかることは珍しくない。本事例では、プロダクトへのインプットとして活用している、既存の社内データ整備の必要性があらわになった。

3) 思考の AI 化における三つのよくある思い込み

本章のまとめとして、CAITO や A 社の事例に加え、その他の生成 AI 導入事例を通じて共通して見えてくる、思考の AI 化を推進する際に陥りがちな「間違った思い込み」について論じる。

(1) 既存のマニュアルをそのまま読み込ませればよいという思い込み

この思い込みは、既存の業務マニュアルを RAG^{※4} にそのまま読み込ませるだけで、熟練者の思考や判断が再現され、業務が効率化されるというものだ。しかし、マニュアルの多くは、定型的な「作業」に重点が置かれた記載になっていることが多く、その背景にある「思考」は十分に言語化されていない。また、「営業マニュアル」のような、一見思考が言

※4 Retrieval-Augmented Generation (RAG) は、LLM によるテキスト生成に外部情報の検索を組み合わせることで、回答精度を向上させる技術のこと

語化されていそうなものでも、販売商品ごとの説明に終始し「顧客の現状に鑑みて最適な商品を選び、提案する」といった、より連続的で複雑な、実際の業務シーンにおける思考は言語化されていないことが多い。

(2) 既存業務が完全であるという思い込み

次に、現在行われている業務プロセスや、熟練者の思考プロセスは常に最適であり、それをそのままAIで再現すればよいという思い込みがある。しかし、既存業務には、歴史的経緯や何かしらの制約に起因する非効率性、あるいは長年の慣習によって「思考停止」に陥っている部分が含まれていることが多い。熟練者の思考も、必ずしも常に論理的・網羅的であるとは限らない。AI化を検討するプロセスは、単なる現状の再現ではなく、業務の本質や「あるべき姿」を再考する絶好の機会である。

(3) 既存業務のすべてを言語化し AI化する必要があるという思い込み

最後に、業務のあらゆる側面、判断基準、例外処理などを完全に言語化し、AI化しなければならないという思い込みがある。しかし、業務のすべてを完璧に言語化することは、膨大な時間と労力を要し、現実的ではない。実際には、多くの業務において、個別のケースに対応する際にも、その根底には「共通の考え方」や「判断の原則」が存在する。つまり、「思考のAI化」は業務のすべてをAIに代替させることではないと認識し、AI化の対象となる業務範囲を明確にしたうえで、個別のケースを網羅的に言語化することではなく、多くの業務に共通して適用される考え方や原則を抽出し、これを言語化することが重要である。

4 おわりに

本稿では、生成AIの真価は「思考のAI化」にあると示し、対象業務の選定から思考の言語化・構造化、プロダクト実装・磨き上げまでの要諦を論じた。

筆者は改めて、生成AIはあくまで手段であると考えている。企業の生成AI導入初期に多く見られた「生成AIならうまくやってくれるだろう」という期待は、生成AIの活用が業務の深部に踏み込むほど現実とかけ離れていく。だからこそ、業務の何を革新させたいのかを明確にし、現状の業務がどのように回っているのかを言語化したうえで、小さな検証サイクルを回しながらプロダクトを作りこむ必要がある。とはいえ、この考えは生成AIの可能性を矮小（わいしょう）化するものではない。正しく設計された生成AIプロダクトは、人間の知的能力を拡張し、組織の競争力を飛躍的に高めると確信している。本稿で示した要諦が、企業における生成AI活用の正しい意思決定の一助となれば幸いである。

(監修：大道 亮)

筆者



久米 脩平 (くめ しゅうへい)

株式会社 野村総合研究所
AI戦略コンサルティング部
コンサルタント

専門は、データサイエンス、DX・業務改革など。直近では生成AIの利活用支援やユーザー・アプリケーション・データの分析支援などに関わる

E-mail: s-kume@nri.co.jp