

経営としてDXに向き合う思考技術（後編）

問題意識の成熟度を高める



福原英晃

CONTENTS

- I 生成AIが加速させる企業のAI活用
- II AI導入の本質は「組織経験知の再現」と「競合差別化」
- III AI導入における課題と対応方法
- IV 次世代テクノロジーを現場実装・価値創出に導くリーダーシップの要諦
- V おわりに：「思考技術」を駆使して議論と意識を引き出す

要約

- 1 ChatGPTなど生成AIのビジネス利用が加速している中、「自社育成AI」の導入に苦戦・停滞している企業は多い。AI導入のような、高度なデータ利活用を伴うDX推進における課題への対応には、多くの経営的示唆が含まれている。
- 2 AIの能力の根源は、企業独自の「因果関係データ」から「組織経験知」を超人的な速さで習得・再現できるところにある。この能力を顧客ニーズへの対応や生産性向上などの価値実現につなげることで、競合差別化を図ることが可能となる。
- 3 他方、未知で異質なAIの導入には困難も多い。適切な期待値を設定すること、AIから価値を引き出す業務上の要求・要件を見抜くこと、現場に現状変更や新たな試みを促すことなど、技術面にとどまらないマネジメント上の難しさが伴う。
- 3 企業変革に挑むには、社内の「問題意識の成熟度」を「Why?→What?→How?」の順番で高めることが必須である。特にAI導入のような深層DXの場合には、「Why?：現状への危機感」「What?：価値ある組織経験知」「How?：現場のAIメンター意識」それぞれの意識と理解の醸成が要諦となる。
- 4 DX成功企業の共通点は、経営によって引き出された「議論の質」と「問題意識の成熟度」の高さにある。「思考技術」を駆使し、向き合うべき課題を見極め、目標を指し示すリーダーシップにこそ、DXの成否がかかっている。

I 生成AIが加速させる 企業のAI活用

1 企業のAI活用が本格化する予兆

デジタルトランスフォーメーション（DX）にはさまざまな技術領域が含まれているが、その長く続く活況を牽引している主要技術の一つがAI（Artificial Intelligence：人工知能）である。


AIは話題としての露出が高い一方で、「DX白書」2023年度版に掲載されている、2022年6月から7月にかけて実施したアンケート調査結果では、日本企業におけるAI導入率（「全社で導入している」「一部の部署で導入している」の合計）は22.2%となっている（図1）。06年のディープラーニング実用化をきっかけとした「第3次AIブーム」の勃興からは15年以上が経過しているが、まだ大き

く普及が進んでいる状況とはいえない。

しかし、22年11月に公開された米Open AIによる「ChatGPT」が火付け役となり、23年に入り日本でも生成AIの話題が沸騰している。それによる影響は短期間でビジネス領域にも波及しており、野村総合研究所（NRI）による23年5月時点の調査では、生成AIのビジネス利用は「実際に活用中」が3.0%、「トライアル中」は6.7%に至り、「検討中」を含めると2割近くに達している（図2）。また、その翌月に帝国データバンクが行った調査では、生成AIを「業務で活用している」は9.1%、「業務での活用を検討」は52.0%までになり、合わせて6割を超えている（図3）。

Webブラウザやスマホアプリを通じてすぐに試して機能を実感できることも、半年足らずでここまでの関心を集めるに至っている要因であろう。Open AIに対しては、Micro-

図1 AI活用の状況



softが複数年にわたって数十億ドル規模の投資を表明し、その勢いを後押ししている。またGoogleやMetaをはじめとするビッグテック各社も、それぞれの特色を出しながら、対抗するLLM¹⁾製品を開発・発表している。さらに、それらの機能を便利かつ高度に活用する周辺技術も急速に発展しており、今後はこれら生成AIが牽引する形でAIのビジネス利用が加速すると見込まれる。

2 「自社育成AI」はデータ利活用による企業変革の試金石

『知的資産創造』2023年9月号の「経営としてDXに向き合う思考技術（前編）」（以降「前編」）で論考したように、DXの文脈で考えた場合、「AI」にはいくつかの系統がある。大きく分けて、外部ベンダーによって学習が完了しているAIを搭載した「既製品AI」と、主に自社にて独自のデータを学習させる「自社育成AI」の2つがあり、それらの特性や導入目的は大きく異なる。

「既製品AI」の例には、AI OCR（文字認識）・AIマイク（音声認識）・AIカメラ（画像認識）などがある。これらは特定の認識タスクが遂行できる学習済みAI製品であり、データ・環境・技術者を自社で準備する負担も少ないことから、導入企業も増えている。

一方の「自社育成AI」は自社で収集・蓄積した独自のビッグ・データをAIアルゴリズムに学習させ、オリジナルの推論（予測・分類など）機能の実現を目指すものである。この推論機能により、競合他社との差別化につながる新たな顧客価値・経済価値の創出が期待できる一方、データ・環境・技術の内製や、ビジネスオペレーション、システムエンジニアリング、データサイエンス各部門の綿密な連携が不可欠となり、DXの中で最もチャレンジングな取り組みとなることから、「データ利活用による企業変革の試金石」ともいえる。

上述の調査結果が示すように、現時点でAIに取り組んでいる企業はまだ多数派とはいえないが、既に一部の先進企業では、難易度の高い「自社育成AI」の導入にチャレンジしており、具体的な成果を上げながら進化

図2 生成AIの職場における導入・検討状況（勤務先の業種別）





図3 生成AIの活用状況



を続けている。

一方で、難易度の高さから苦戦・停滞している企業も見られる。苦戦・停滞の原因は、必ずしもAIや情報システムなど技術的なものばかりとはいえ、プロジェクトマネジメントや経営のリーダーシップに問題があることも少なくない。この問題の考察から得られる学びは、AI導入だけでなく、高度なデータ活用を目指すDX全般に適用可能であり、経営的示唆にも富んでいる。

次章以降、AIとはどのような特性を持った技術なのかをあらためて確認するとともに、AI導入において何につまずきやすいのか、そもそもAIやその導入は企業や現場にとって何を意味するのか、そしてそれを企業変革に結びつけるリーダーシップの要諦はどこにあるのか、NRIがDXに関する推進支援

やディスカッションをしてきた企業の事例を参考にしながら考察していきたい。

3 補論：DX思考フレームワークの確認

次章以降の論考は、「前編」で紹介したフレームワークやキーワードへの理解を前提とした記述があるため、それらをここで簡単に解説しておく。詳細については前編を参照されたい。

(1) 4階層V字モデル

DXの全体観・構造観を表した思考フレームワークである。DX実現後のデータ活用を①～⑦の流れで表現している（図4、5）。

まずもたらされたDXに関する話題が、この4階層V字モデル内①～⑦のどこを対象

図4 DXの4階層V字モデル

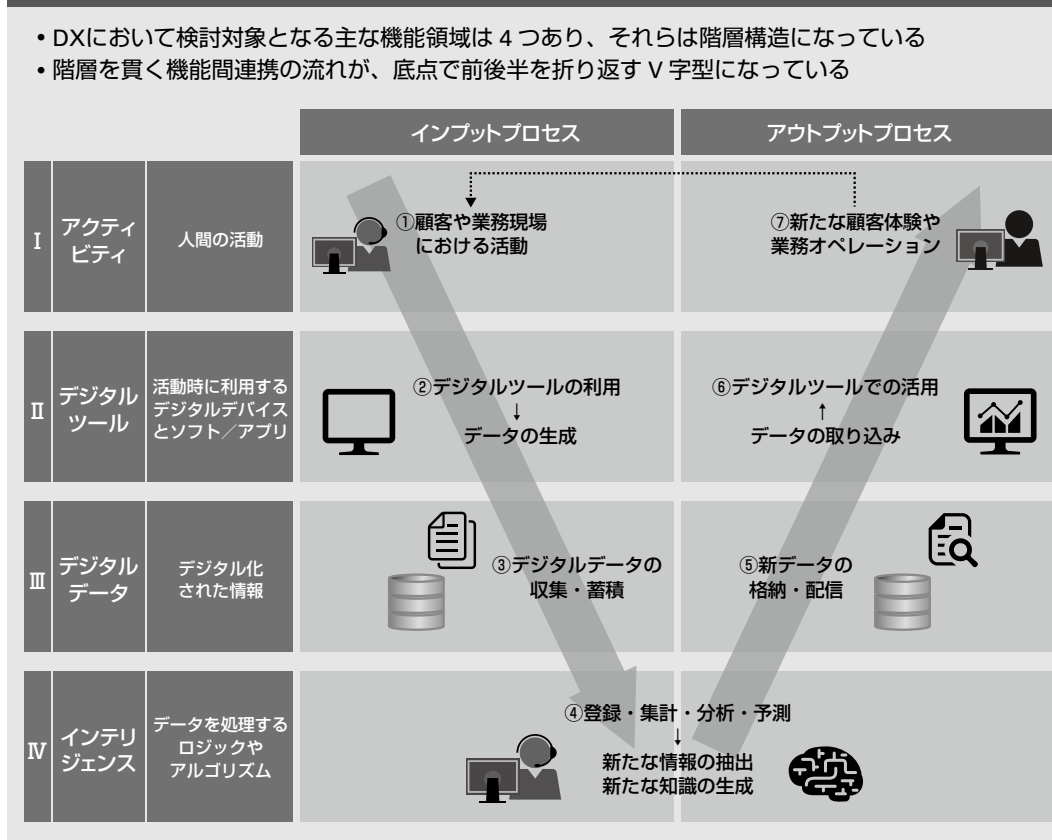
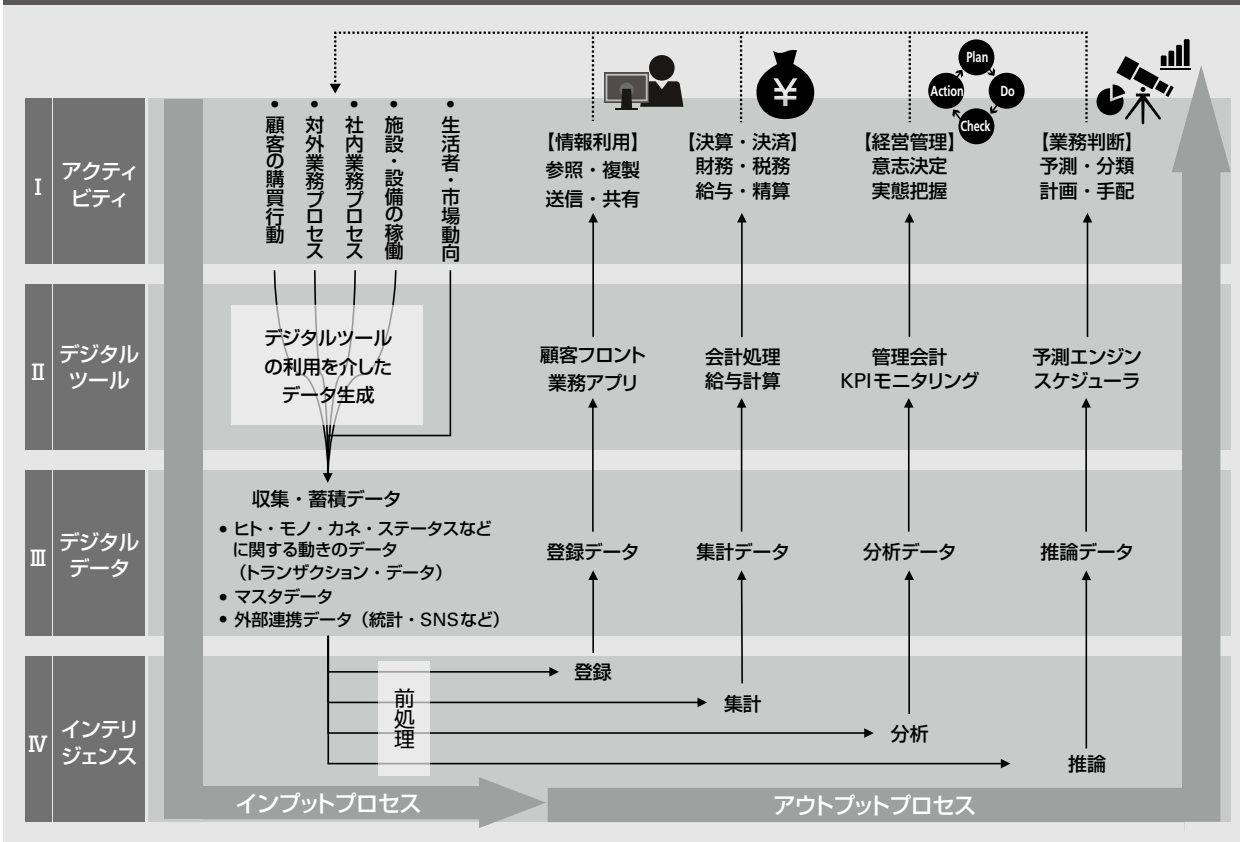


図5 4階層V字モデルの基幹業務への適用イメージ



としたものなのかを最初に確認することで、「DXのどの部分の話をしているのか」という大前提レベルからの認識齟齬の発生や、噛み合わない空中戦を回避することができる。

(2) 自社育成AIと深層DX

本稿では基本的に社内データ利活用から新たな価値実現を目指す、正統派ともいえるDXを対象として論を深掘りしている。デジタル情報の利活用を「登録」「集計」「分析」「推論」と深化させることで、データからより深い洞察を得ることを目指す(図6)。

これまで「登録」や「集計」など基本的でシンプルだったデータ利活用を、「分析」や「推論」というV字の深い谷まで掘り下げ、

そこから新たな顧客価値や競争優位性の源泉を抽出し、それをビジネスプロセスに実装するレベルを問われるのが「深層DX」である。谷が深くなるほど、未知の技術、斬新なビジネスプロセス、複雑な層間連携が必要となり、組織として対応の難易度も向上する。

「自社育成AI」はこの最深部に至る「深層DX」の一種であるとの位置づけで論じることとしたい。

(3) DX基本構想

4階層V字プロセスを実際に企画・設計する段階において策定・活用する思考フレームワークである。「目的を踏まえて手段を考える」という思考の方向性のためV字モデ

図6 V字モデルとデータ利活用の深化

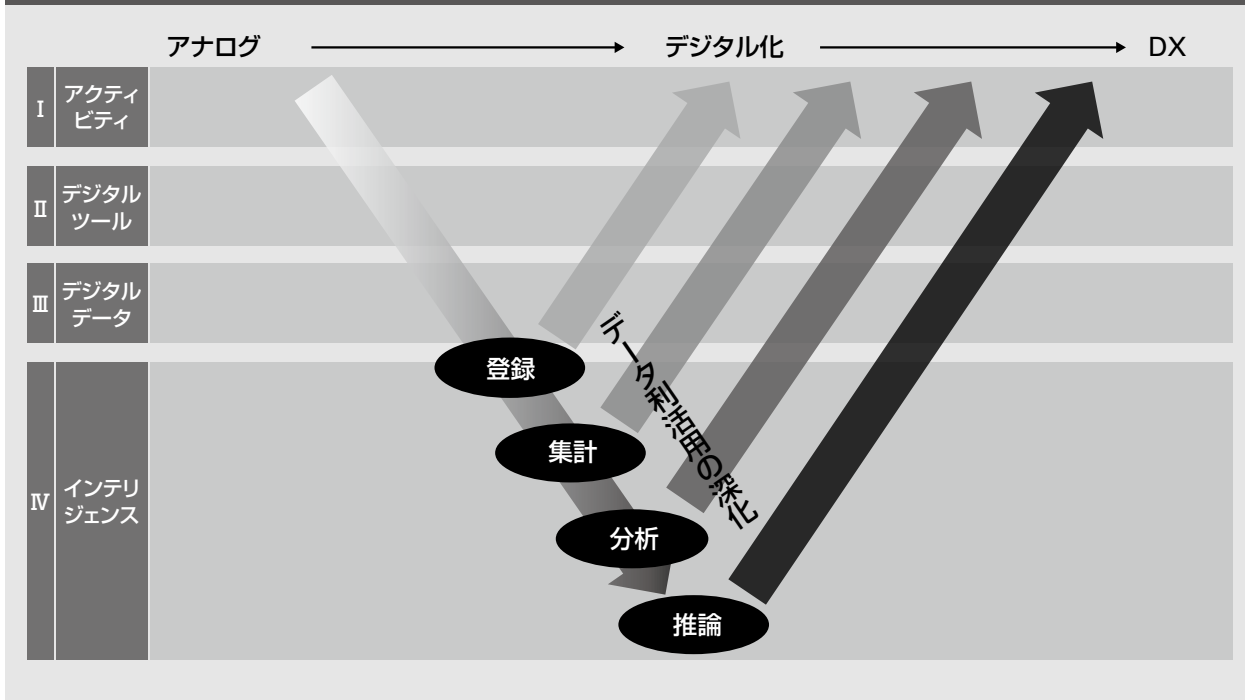
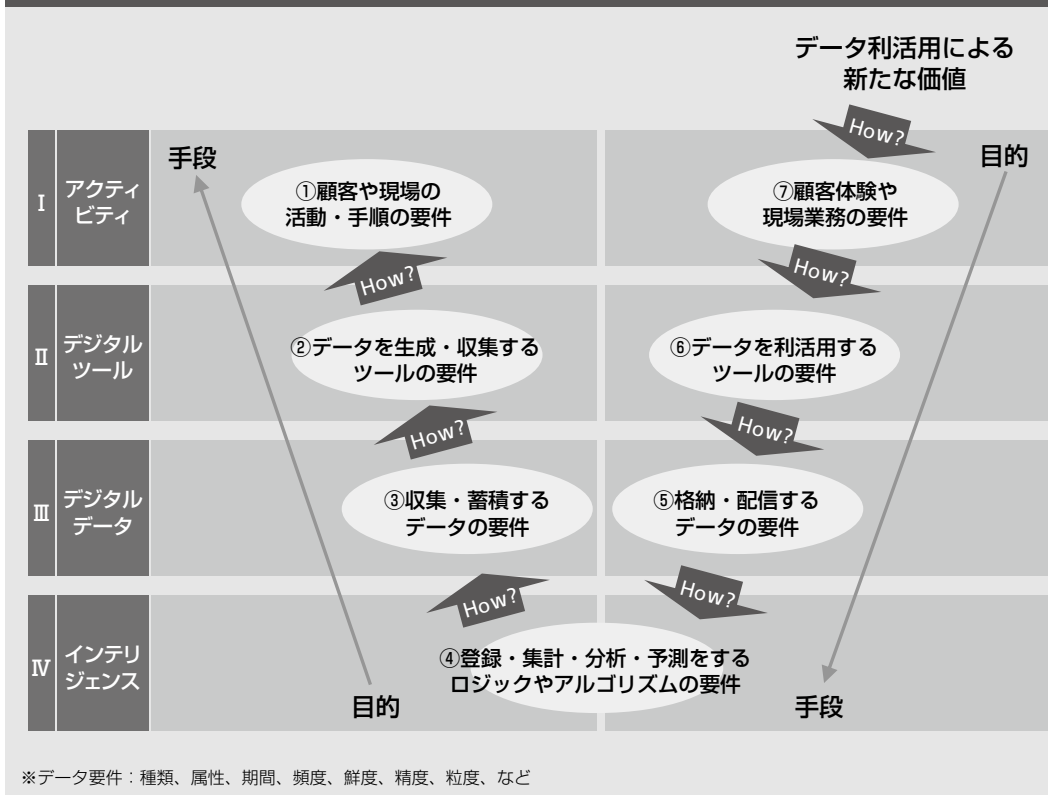


図7 DX基本構想（目的→手段の要件連鎖構造）



ルとは流れの方向感は左右逆になる（図7）。

企画・設計の初期段階では、この俯瞰的な連鎖構造をコンセプトレベルで描いた「DX基本構想」を早い段階で経営として合意しておきたい。立ち戻って確認できる基本構想が存在することは、各階層機能の詳細作り込みでの要件不整合を回避したり、PoC（Proof of Concept：実証実験）・現場実装段階における関係者間の利害衝突を緩和したりと、効率的で建設的なプロジェクト推進の助けになるはずである。

II AI導入の本質は 「組織経験知の再現」と 「競合差別化」

本章ではまず、以降の前提理解となるAIの能力特性や知識生成方法、およびそれらをビジネス利用することの意味について考察したい。

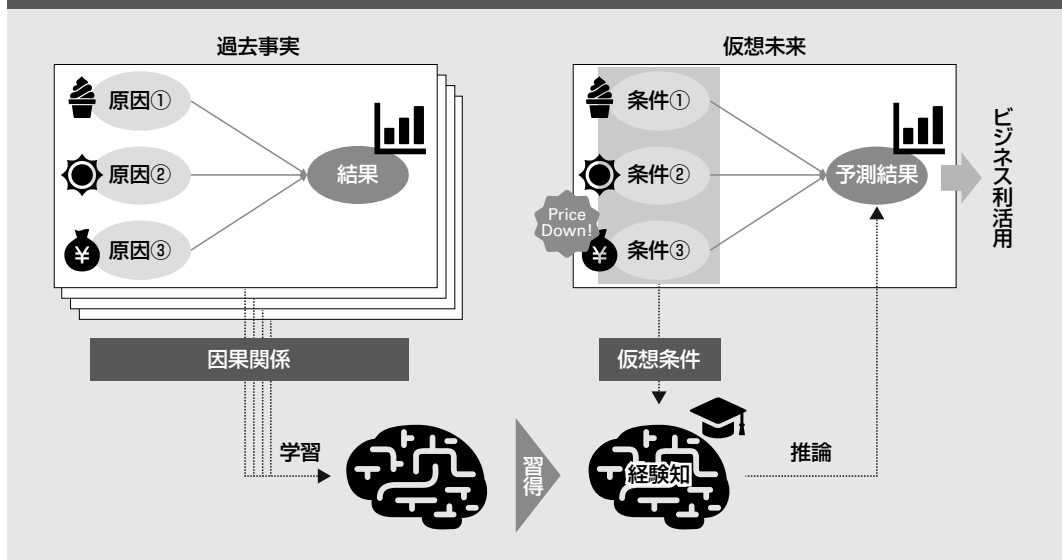
1 AIと従来コンピュータとの違い

これまでコンピュータが主に担ってきた登

録・集計などの機能に対し、AIができることは異質である。AIは、与えられたビッグ・データの中に潜んでいる因果関係の発現パターンを学習する（図8）。因果関係とは、単純な例では「(要因) 天気がよいと⇒(結果) 売上が上がる」「(要因) 40代男性が商品Aを買うと⇒(結果) 商品Bも買う」など、ある状態や発生事象を要因・原因としてほかの事象が結果として発生するという、状態や事象同士にある結びつきの強い関係性のことである。

AIは、これら「因」と「果」の関係性を少し「緩さ」を保ちながら学習し、人間における「カン」や「コツ」のような曖昧さ・柔軟さを含んだ判断能力を獲得している。この一見「いい加減」とも思える「曖昧さ・柔軟さ」がAIの底知れぬ可能性の根源ともいえ、その能力を駆使することで未知の応用問題を扱うことができる。従来のコンピュータは、事前に因果関係が数理的・論理的な厳密さをもって定義され、その関係式を構成する変数のすべてがそろっていなければ答えを出せない。ここがAIと従来のコンピュータが決定

図8 AIによる因果関係の学習と経験知の習得イメージ



的に違う点である。

われわれ人間も、何かしらのエキスパートになる成長過程で類似のことを行っている。たとえば、仕事についての最初の見習い期間はマニュアルや先輩の手取り足取りの指導に従って「AのときはBをする」と、曖昧さやブレのない因果関係を再現することを仕事とする。見習い期間が終わると、パターン化できない、もしくはルールや法則として厳密に定義し切れない、応用的な仕事に向き合うことが求められ、その対応精度を上げるために「経験」を積む。その経験値の蓄積は頭の中で抽象化され「こういう感じのときは、おおむねこの方法をとるのがよいだらう」など、曖昧でブレもありながら、未知の状況でも対応できるようなる。この対応能力の積み重ねが人間にとっての成長実感につながるわけだが、AIが獲得できるようになったのも、まさにこの応用性の高い因果関係、つまり「経験知」の再現能力である。その能力を用いて、状況・判断・行動など結果に影響を与える前提条件を「もし〇〇だったら」と仮想的に変化させたときに起こり得る結果を予測

し、それをビジネスに利活用することで価値を実現する。

コンピュータを用いた予測という観点では、従来型のコンピュータにも、回帰分析やシミュレーションなどを用いた推論技術は存在した。しかし、その推論のためには、回帰式や近似解法などを用いて因果関係を厳密に数式化、形式知化する必要があった。AIはその因果関係を暗黙知²として学習・推論しているため、原因と結果のそれぞれのデータさえあれば、その関係性を人間が介在して形式知化する必要がなくなった点が大きい。

2 自社育成AI導入の意義は「組織経験知」の再現

実際にビジネス領域でAIが学習する因果関係データと、それによって獲得する経験知のイメージを表1に示す。

表1の左端にあるそれぞれの「業務領域」の現場（行動主体が顧客もしくは生産機械などの機器の場合も含む）では、「原因データ」欄に示しているように、時々の前提条件の下で判断や行動・稼働をしている。その結

表1 ビジネス領域における因果関係データと組織経験知、実現価値

業務領域	原因データ (前提条件と判断・行動)				結果データ	再現したい組織経験知		実現価値
	顧客属性	商品属性	レコメンド内容	...		指南者	経験知	
販売	顧客属性	商品属性	レコメンド内容	...	販売実績	全顧客	別顧客の関連購買	今まで気づかなかった顧客ニーズの充足
販促	販促キャンペーン内容 (内容、期間)	店舗属性 (立地、面積、商圏人口)	過去売上推移 (カテゴリー別)	...	販売実績	全国の類似店舗	販促キャンペーンの効果	費用対効果の高い販促
営業	商談内容 (ステータス、使用資料)	顧客属性 (業界、規模、部署)	提案内容 (種別、価格、期間)	...	発注意向ステータス	全国の営業担当者	次に打つべき商談アクション	商談期間短縮、スキルの平準化
間接材料購買	資材仕様	気温・湿度	生産ライン別稼働時間	...	資材使用実績	全国の工場	必要資材の消費量	欠品・緊急手配コストの抑制
生産管理	生産数量実績	設備センサデータ (温湿度、振動、臭気)	設備メンテナンス情報 (部位、時期、内容)	...	設備故障実績	全国の類似設備	設備故障のタイミング	メンテ回数削減、稼働率の向上

果としてビジネス上の状況が変化し、「結果データ」欄のような実績値のデータを蓄積している。AIが学習している因果関係とは、この原因データから結果データが得られる法則性である。

企業がAIを導入する大きな意義は、学習対象である因果関係が「個人」ではなく「組織」として幅広く蓄積したデータであり、そこから「組織経験知」が得られるという点にある。

基幹・業務システムや顧客・取引先フロントシステム、もしくは施設や設備IoTや監視制御系システムなど、企業が有する多種多様なシステムから収集・蓄積されたビック・データのすべては因果データとして学習対象になり得る。言い換えるなら、AIにノウハウを教え込む「指南役」はその業務を経験しているすべての顧客・社員・組織・設備ということになり、AIはその経験一つひとつをすべて学習する。これによって、AIは個人レベルの経験では到底得られないような高い精度と応用性を持った経験知を、まさに超人的な速さで身につけることができる。

3 「組織経験知」の再現で 得られる価値

そして、自社育成AIを導入することの真髄は、世の中で自社しか持っていない「原因データ」と「結果データ」にある。そこから完全オリジナルの「組織経験知」を取り出し、それを新たな顧客ニーズや人的生産性の向上、オペレーションのスピード化などのビジネス価値につなげられれば、「既製品AI」からは得られにくい、競合他社との差別化を実現することができる。

表1に掲載した業務イメージはすべて、一定の具体的な成果を得ている事例である。各種メディアを通じて見聞きする「売上が前年比〇%上がった」「人手不足のところ〇人削減できた」「リードタイムが〇日に減った」などの自社育成AIによる成功事例は、このような因果関係データを活用した組織経験知の再現と、そのビジネス現場への実装による成果を表したものともいえる。

一方、前章でも触れたように、すべてのAI導入のチャレンジが順調に進んでいるわけではない。というより、決して少なくない数の企業がAI導入チャレンジで苦戦・停滞している実態を踏まえると、「難易度は相当高い」という方が正しいだろう。また、同じく前章でも触れたように、それらの問題の原因は、技術面というよりマネジメント面にあることも少なくない。実際にどのようなチャレンジングな状況が発生するか、次章で事例とともに確認する。

III AI導入における課題と 対応方法

本章では自社育成AI導入時の具体的な課題と対策について考察する。なお、本章以降では特に断りなく「AI」と記述するものは「自社育成AI」を指し、それをコアエンジンとして搭載した業務アプリケーションシステム全体を「AIシステム」と表記する。

1 ビジネス要求・要件の考慮が 不足した事例

最終的にAIがどのような情報を提供すれば人間や業務にとっての価値につながるの

か、その要求・要件が十分に考慮されていないと、どんなに高精度なAIを作り込んでも業務現場では価値を発揮できない。

ケース① 製造業 工場資材発注業務

「コスト削減の観点で大事なのは、翌週ではなく翌月の予測だ」

工場のコスト効率化を支援する目的で、資材発注業務でのAI導入の検討を開始。アイテム数ベースでは納期1週間のものが多いため、業務工数削減の観点で翌週の資材使用量を予測するAIの開発を進めた。しかしPoC直前で、ターゲットを納期1カ月の海外調達アイテムに変更。通常は船便のところ航空便に変える緊急発注がたびたび発生しており、その余剰コストの削減の方が、はるかに効果が高いとのこと。納期1週間アイテムは納期・使用期限・単価を考慮すると在庫補充方式で十分との判断に至る。

顧客や業務現場に関するビジネス上の知見のことを、データサイエンティストは「ドメイン・ナレッジ」と呼び、データ分析やAIを搭載したアプリケーションを開発する際に参照する。業務で使うデータが、時間軸・空間軸・商品軸・顧客軸などの単位系において、それぞれの粒度で予測することに実務上の意味があるのかは、業務部門にしか分からないドメイン・ナレッジである。

この事例では、翌週予測に関する因果関係の再現を探求したにもかかわらず、ビジネス要求が翌月予測に変わった。このため、前提とする因果関係の根本が異なることとなり、基本的な因果構造アナリティクスのやり直

し、インプットデータと前処理方法の練り直し、AIアルゴリズムや学習方式の再設計など、ほとんどゼロベースからやり直しとなったのである。

もう一つ、類似したケースを見ておこう。

ケース② 食品卸 流通センター発注業務

「出荷予測値だけでは意味がない」

在庫型流通センターにて出荷数量の予測にAIを導入するプロジェクトを開始した。現場省力化とPSI（受発注&在庫量）コントロールの高度化が目的であった。動きのある定番品にターゲットを絞ったこともあり、出荷予測の精度は問題なかったが、発注業務の現場は「出荷」だけでなく「在庫」と「注残（受注残・発注残）」が差し引き計算された「発注」数値が自動計算されなければ、結局手作業が残り、工数やミス削減につながらず意味がないとのこと。WMS（倉庫管理システム）と基幹システムの連携バッチや入出庫のタイミングで正確な注残数がシステムで把握できないなど、いくつかの事情により時間をかけて手作業を行っているため、それもAI予測で補完してほしいとのこと。その後は発注数値が現場の感覚と合致しないという問題がクリアできず、PoC実施の見通しは立っていない。

AIが出力する「予測」の情報だけでは実務上使えない、もしくは省力化目的にはあまり役に立たないということがある。たとえば予測値データを加工したり、ほかのリアルタイムデータとの四則演算が必要だったりとい

うケースである。それらは本来、別の予測AIではなく、「インプット」側のシステム領域の課題として議論すべきである。そこに無理やりAIを適用すると、予測値に予測値を掛け合わせて精度が不安定になったり、データサイエンティストが帳尻合わせの係数パラメータ調整に追われたりすることで、活動全体に疲労と不信が蓄積していくことにもなりかねない。4階層V字モデルを参照しながら、「本当にインテリジェンス層で対応すべきことなのか」「まずはインプット側のデジタルツール階層の問題として既存システムの改修を議論すべきではないのか」などの議論を慎重に行うべきである。

以上の2つの事例からいえることは、ビジネス現場がAIシステムにどのような用途や効用を期待しているのか（要求）、そのためにはどのような機能を具備すべきか（要件）を把握できていないと、ツール自体の性能がよくても結局価値の実現にはつながらない、という従来のITシステム開発と変わらないものづくりの基本である。ただし、AIが担う役割はITシステムとは異なり、現場部門もまだ理解し切れていないため、AIシステムの導入によって解決すべき本質的な組織課題が何かを見定めることは簡単ではない。本質的な組織課題がズレれば、要求・要件も当然ズレるため、後になって「ちゃぶ台返し」も起こりやすい。話がこじれるとAIへの間違った不信感にもつながりかねない。

PoC前とはいえ、時間や投資を無駄にしないためにも、限られた現場担当者との会話だけで要求を決め打ちしてAI開発に着手するのではなく、現場部門の上位者やシステム部門などを交えて多方面から本質課題を議論す

るプロセスを設けることが重要である。

2 AIへの期待値を誤った事例

AIに限らずどんなツールであっても、その機能や役割に対する期待の仕方を間違え、本来の使われ方がなされなかったり、使われた結果が想定と違ったりすると、そのツールが持つ本質的な価値とは無関係に利用者側が幻滅してしまうことがある。

ケース③ 製造業工場生産管理部 生産計画業務

「AIが全然賢くならない。むしろ頭が悪くなっている」

一部の製品カテゴリを対象に生産計画数量設定にAI導入のPoCを実施したが、PoC開始と同時に担当をベテランから新人に変更。受注や内示、在庫、製造ラインの状況変化があったときにAIの反応が鈍くてもAIにいわれたとおりの数値を採用したため、推論精度が低下した。

AIは基本的に何もしないと推論精度が下がっていく。AIが想定していた因果関係の性質や構造は環境変化とともに陳腐化することがほとんどであるため、その変化のスピードに応じた頻度で再学習を実施する必要がある。この「因果関係の性質や構造の変化スピード」をどう捉えるかについては現場の深いドメイン・ナレッジが求められるため、AIシステムの運用要件設計の議論の中で、業務部門が再現したい経験知がどのような性質のものかという議論を十分に尽くすことが重要である。

また、再学習さえ実施すれば必ず賢くなる

わけではない、という理解も重要である。AIはインプットした組織の経験知（因果関係データ）の範囲で推論能力を更新していく。AIの推論結果が自動的に蓄積・循環を繰り返すのではなく、人間がそれを用いて判断・行動し、それが顧客や市場に影響を及ぼし、結果データとなる。つまりAIは放置しておけば勝手に賢くなるのではなく、賢くなるためにはよい手本となる因果関係データを多く残し、逆に再現させたくない因果関係がデータとして残らないよう人間が注視・介入していくことが必要である。上記の例のように、AIの試験運用開始と同時にベテランを業務から外してしまい、状況変化に対するAIの反応の鈍さに人間がドメイン・ナレッジを駆使して注意を払えなければ、やはりAIはうまく機能しない。誤った使い方「AIは使えない」と判断してしまっただけでは宝の持ち腐れである。

このように、ツールの特性や用途に対する適切な理解と期待値を持つことは、特に新規性の高い技術導入の成否に致命的に影響することを理解しておきたい。

ケース④ 小売業店長

「AIに従って新しいことにチャレンジできない」

コロナ禍明けで客足が回復する中、新商品や販促キャンペーンを次々と打ち出すも、AIはコロナ禍期間を含む過去1年の定番品の需要変動を学習しているため、定番の低調な予測数値しか出せない。「AIは現状維持か過去踏襲しかできない」とネガティブな印象を持たれる結果となった。

自社育成AIが目指しているのは、過去に発現した因果関係パターンを組織経験知として再現することである。一方で、催事や販促キャンペーン、新商品発売、特需対応などを組織的に打ち出すことで、過去の傾向から飛躍した「異常値」づくりをあえて目指すときもある。このような創造的な仕事はやはり人間にしかできない。

たとえば、「過去の販促時の実績から2倍の増収効果は狙える」などの因果関係が既に観測されていれば、それは異常値ではないため、AIによる再現が可能である。一方、過去のいかなる事象・傾向も参考にならないような人の意思による新たな目標を追求する場合、組織経験知の「再現」を目指すAIはあまり役に立たない。

AIに対する理解が成熟していないからこそ「人間とAIの仕事の棲み分け」を早い段階から現場と議論しておくことが大事であり、それが結果的にAIへの適性理解と期待値を健全に培うことにもつながる。

3 仕事のあり方があらためて問われることになった事例

AI導入を検討する過程では「AI以前の問題」と遭遇することが多い。現場任せで個別最適化が進み、旧態依然としたままの業務が問題となり、そのあり方をあらためて問い直す必要に迫られるケースも決して少なくない。

ケース⑤ サービス業 フランチャイズ (FC) 店舗開発業務

「現場の日常業務に支障を来すようなことまでやりたくない」

新規出店や店舗改装による増益効果を予測するAIを開発できるか検討をスタート。関係部署に業務や使用システム・データの実態をヒアリングしたところ、予測に必要な原因データの発生源となる業務は「不動産探索・賃料交渉」「土地設計・建築・修繕」「看板・什器・店内レイアウト」「ローカル販促・集客」「店内オペレーション教育」「FCオーナー管理」など多岐にわたり、それぞれの責任部署でシステムもデータ管理もバラバラで、一部は各人PCのエクセルによって行われていた。物件IDをキーとして関係データを定義し、それらの抽出・突合・蓄積を自動化するには業務やシステム、組織の抜本的な変革が必要になる。人手不足の中での業務の品質や継続性、FC契約上の本部管理権限などに対する現場ベテラン社員からの不満噴出が懸念されたため、AI開発はいったんストップし、全体構想レベルの整理からやり直すこととした。

これまで業務やデータ基盤を全社最適の視点で整備してこなかった現場にいきなりAIを入れようとしても、やはりなかなか難しい。日々の業務活動が因果関係データとして蓄積されていなければ、それを組織経験知としてAIで再現することはできない。したがって、まずはデータを収集・蓄積するために、4階層V字モデルのインプットプロセスの再整備が必要になる。

上記の例では、属人性の多く残る業務プロセスを標準化したり、それを支援するワークフローシステムを開発したり、それらの運用

を通じてAIが必要とする「因果関係」として活動データやマスタデータが登録・更新されるようなデータ・マネジメントの基盤を構築したり、ということが必要になる。

しかしながら、データを収集する業務オペレーションの従事者が、AI導入による直接の受益者になるとは限らず、「自分にメリットがないので現状を変える理由がない」という意向と対峙しなければならないことがある。また、一部の業務やデータを外部事業者に依存していて、問題が社内だけで完結しないケースもある。こういった場合には、最初からAI導入を前面に押し出すのではなく、業務改善や顧客サービスレベルの向上、各ステークホルダーのインセンティブなどと方向性を整合させながら、インプットプロセスの整備を着実に進めるような議論の舵取りが重要となる。経営層がよりリーダーシップを発揮すべき課題となるため、次章にて掘り下げて議論する。

ケース⑥ 製造業 代理店による補修部品発注

「人間がやっていないことはAIにやらせない」

代理店からの直前発注が原因で、部品欠品・修理対応遅れ・顧客苦情が頻発していたため、AIによる発注補助システムを開発。「代理店は、ただ指示どおりに発注すればよいシステムでなければ使わない」という代理店営業の意見により、修理依頼件数のAI予測から必要部品数を計算して提示するツールを開発し、直営店でのPoCも実施した。しかし、代理店への展開前に営業側から「代

理店それぞれで事情が異なり、発注指導の方法は統一されていないので、現場はAI予測のロジックを聞いてもピンとこない。もしAI予測が外れて欠品したらメーカー側の責任として売上補償などの問題にもなり、今はそんなリスクは負えない」と不安の声が挙がり、プロジェクトは中断となった。

AIはたとえ組織内で形式知化・標準化されていないノウハウであっても体得することができる。製品故障や修理依頼について、件数の増減を説明するのに十分な原因データ（季節、地域天候特性、管轄エリア内台数・年式、ユーザー属性など）があれば、その増減メカニズムに人間にとっての暗黙知が含まれていても、AIが予測することは可能である。しかし、その予測を人間が信じて活用できるかというのは、また別の問題である。

まずここで考えたいのは、今回の活動を機に、現場任せになっていた業務の標準化を進められないか、ということであろう。AIが一定の予測精度を確立できているのであれば、因果関係を説明するデータが手元にあるということであり、「おおむねこれらのデータの変化から修理件数増減の予兆を掴める」などのノウハウを言語化し、代理店に指導することは可能である。「人間がやっていないことはAIにやらせない」とすぐに結論づけるのではなく、AI化の過程で得た形式知化可能なノウハウを業務標準として設定し、まずはアナログで業務レベルの底上げを図るだけでも十分に価値がある。それがAIの予測根拠への理解や説明力の礎となり、未知なるAI導入への不安低減につながる。

次に考えるべきは、このような「経験的な思考・判断能力の機械化」を組織として受け入れられるかどうかだが、これもまた全社レベルの経営課題とも関連するため、次章で考察を深めることにする。

IV 次世代テクノロジーを 現場実装・価値創出に導く リーダーシップの要諦

本章では、これまでの議論を俯瞰的な視座から捉え直し、DX推進を舵取りするリーダーシップの要諦として整理したい。まずはその整理の枠組みを説明する。

NRIでは（DXに限らず）変革活動を推進するに当たっては、「Why?→What?→How?」の順序を重視している（図9）。

- ①Why?（理由）：なぜ変革しないといけないのか？
- ②What?（目的）：何を変革するのか？
- ③How?（手段）：どう変革を実現するのか？

経営にとって変革活動の本質は、痛みや困難にチャレンジする社内の問題意識や当事者意識を段階的に成熟させる作業にあるといえる。Why?→What?→How?はその成熟度のバロメータであり、その度合いに応じて活動内容を区切るフェーズでもある。段階の見極めや順番を間違えると、関係者の意識が「総論賛成・各論反対」や「手段の目的化」などの状態に陥りやすく、変革は絵に描いた餅に終わる。NRIが意見交換した企業の経験談や、筆者自身の体験や反省の範囲でいえば、変革活動の苦戦・失敗のほぼすべては、この成熟度の見極めや活動順序の間違いによ

って起きている。

そしてDXとはその名のとおり、デジタル技術を駆使した変革活動にほかならず、特にデータ利活用の深層に及ぶAIの導入は、前章でも紹介したようにチャレンジな状況が多種多様に発生する。その中で経営の仕事としてWhy? →What? →How? の成熟度を順番に高めるためには何がポイントになるのかについて、以降で整理を試みたい。

1 Why? : 現状に対する危機感を醸成・共有する

まずは「Why? : なぜ変革しないといけないのか?」についてである。

前章で紹介した事例を概観すると、共通項として「現場の受け身姿勢」が透けて見えてくる。どの事例の現場も、非協力的なわけでも不真面目なわけでもない。ただ受け身なのだ。実はこの「協力的で真面目な受け身」こそが、DXにとって大きな障害となる。当初は前向きな雰囲気や活動が進捗するが、本番が近づくと実務に与える影響やそれによる不

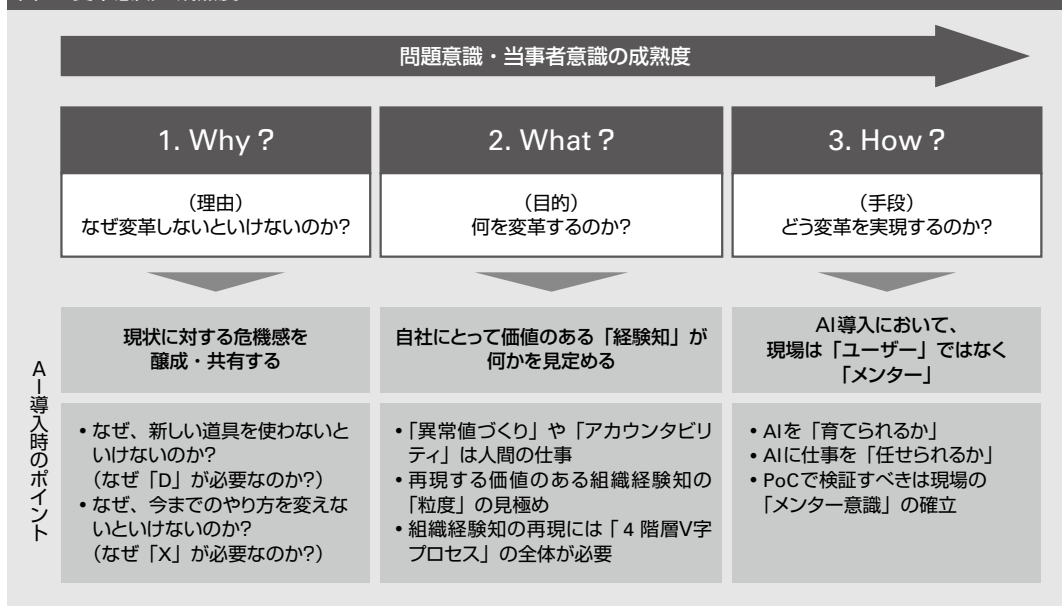
安が具体化し、他責志向の要求・ダメ出しが増え、実装に至らないか、実装後に使われずに終わることがあるのだ。

このような状況を回避するために経営として大事な仕事は、まず現場が大きく2つの「Why?」、つまりDXの「D (Digital)」と「X (Transformation)」それぞれに挑む理由に自問自答できるほどに意識が成熟しているか確認することだ。

・なぜ、新しい道具を使わないといけないのか? (なぜ「D」が必要なのか?)

「組織経験知を再現」するAIは、新たな価値を生み出したり、人的生産性を向上させたりする可能性を持つ一方で、現場にとって未知で異質な道具である。日々の業務に追われる現場では、ただでさえ新しい道具には拒否反応を示しやすい。また、まだ機械に任せる感覚や方法が養われていないことも往々にしてある。そこに次世代ツール導入となれば、「なぜ、この新しい道具を使わないといけないのか」という質問に答えられるような、そ

図9 変革意識の成熟度



れ相応の切羽詰まった理由が必要となる。

・なぜ、今までのやり方を変えないといけないのか？（なぜ「X」が必要なのか？）

そしてAIを現場で活用し、さらにAIから能力を引き出すための大前提として問われるのが「なぜ、今までのやり方を変えないといけないのか」の質問に答えられる意識を導入現場に醸成できるかということである。

「X」とはトランスフォーメーション、つまり企業における構造改革の意味であり、それはAs-Is（現在の姿）をTo-Be（ありたい姿）に変革する活動のことである。しかしながらこの「As-Is」は、過去からの経緯・しがらみやノウハウ、既得権益などが複雑に絡み合ったものの集大成であり、それに携わる当事者としては、変えない方が合理的であることがほとんどである。多くの企業では、「As-Is」が身軽なスタートアップや、変革遂行に強力なトップダウンが効く企業のように事が進まないのが現実だろう。手中にある合理性を捨てざるを得ないほどの強い理由がなければ、ちょっとした障害で「やっぱり不合理だ」となって停滞するか、そもそも変革のスタートラインに立つことすらできない。

これらの「Why？」の問いに業務現場が自らの意思で答えを出せるような企業に共通する要素は、「As-Is」に対する強い「危機感」である。「『As-Is』のままだでも何とかなる」もしくは「変えない方が合理的」と考えている現場からは、上記の質問への答えは出てこないだろう。「受け身」の姿勢では、特にAI導入のような深層DXを、他責に逃げずにやり切る気力やチームワークの発揮は期待できない。時間と投資を浪費する前に、活動

をいったん中止してでも経営にとって最も重要な「危機感の共有」という仕事を優先した方が、結局は近道で効率的である。

今のままの仕事のやり方では、この先の環境変化に対応できず、競合に競り負け、顧客の期待に応えられなくなる。そのようなホラーシナリオを、リアリティを持って語り伝えることで危機感を醸成し、変革に臨む社内の精神基盤を構築することこそ、「DXリーダーシップの真髄」といっても過言ではない。

2 What? : 自社にとって価値のある「組織経験知」が何かを見定める

社内関係者が「Why？」で変革しなければならない理由に納得したとすれば、次に必要な共通認識は「What? : 何を変革するか？」である。変革の大きな方向観は、改革ビジョンや基本方針などとして整理されることが多く、前編では「DX基本構想」を策定するフレームワークを紹介した。さらに、DXの中でも自社育成AI導入の深層レベルを目指すうえでは、経営としてもう一步踏み込んだ共通認識が得られるような議論を喚起しておきたいところである。その内容を確認していこう。

AIで実現できることは、魔法のような未来予知ではなく、過去に自社で経験した因果関係を「組織経験知」として学習させ、その経験知を基に、仮定した未来の状況において何が起きるのかを再現することである。そしてこの因果関係とは、ある時間・場所・状況などの特定条件下において現場が取った判断・行動と、それによって引き起こされた顧客体験・業務成果・経済効果などとの間にあ

る法則性のことである。

企業では日々多くの現場それぞれで判断・行動がなされ、それによる何かしらの結果が発生しているが、それら無数の関係性一つひとつすべてを整理・検証しているわけではない。しかも「紙」や「口」などのアナログ手段を経由した情報の場合、検証以前に事実の保存すらされていないことも多い。つまり、企業内には数多くの組織経験知が活用されずに眠っていたり、捨てられたりしている。こういった経験知の中には表1で例示したような、これまでにない顧客価値や経済価値につながられるものが含まれているはずである。

そのような問題意識に基づいて経営の視点から価値の仮説を見定め、業務部門を巻き込んで議論し、現場の当事者意識にまで成熟したとき、AI導入に挑むための「What?」が完成する。そこで目的として設定された価値とは、自社独自の組織経験知から生み出された完全オリジナルの価値であり、既製品AIから得られる汎用的な利便性とは違った、競合差別化への貢献が期待できるものでもある。

ただし、前章の事例も踏まえて「What?」の対象を設定するにあたって留意点が3つある。

(1) What?の思想：「異常値づくり」や「アカウントビリティ」は人間の仕事

ロジックや過去の経験では説明・再現ができない「異常値」を生み出すような、新規性・創造性に富んだ仕事は、これからも人間の仕事であり続ける。逆にいえば、組織が過去に経験していないような事象の予知や、挑戦的な意思や目標の揭示などをAIに期待することは禁物である。そのような「人間と

AIの仕事の棲み分け」のイメージ形成も「What?」における大事な論点である。

また、能力的にはAIが遂行できることでも、ステークホルダーに対する「アカウントビリティ（説明責任）」を伴うものは、AIに判断を丸投げすることが適切ではないこともある。顧客や株主、債権・債務者、規制当局、地域社会、そして社員個人など、それぞれにとっての重大な利害に直接かかわるような判断においては、その根拠を問われたときに「AIの判断によるものです。」と回答することが法的・倫理的に問題となるケースもあるだろう。今後、AIを取り巻く責任や権利に関する社会的議論や法整備が進展することも想定されるが、少なくとも現時点での「What?」議論は「アカウントビリティは最終的に人間が担うべき役割である」という前提で行うのが現実的だろう。

(2) What?の粒度：再現する価値のある組織経験知の粒度の見極め

ここではAIが学習する組織経験知の「粒度」について確認しておこう。粒度とはAIが最終的に推論結果として出力するデータの「軸」と「単位」のことである。たとえば「売上」という指標のデータ粒度は、下記のような軸と単位の組み合わせで扱われているだろう。

- 商品軸：全商品→商品大分類→小分類→個別商品
- 顧客軸：全顧客→エリア本部別→業種別→個別顧客
- 時間軸：年→半期→四半期→月→週→日→時間

それぞれの軸においては、左端の総計粒度

から始まり、右にいくほど粒度は細くなる。これは基本的に組織階層別の管理レベルにも対応しており、左にいくほど経営管理レベルの粒度、右にいくほど現場オペレーションレベルの粒度になる。

これを前提としたときに、「What?」の議論で見極めておくべきは、AIで再現することに価値のある組織経験知の粒度は、どの管理指標におけるどの軸・単位の組み合わせなのか、ということである。つまり「顧客レコメンド」「販促」「商談」「発注」などを行う各種業務領域の現場において、経験知を活かした判断やアクションは、「商品カテゴリ別×顧客業種別×週別」なのか「個別商品×個別顧客×日別」なのか、どういった粒度の組み合わせで発揮されているか。そしてそれをAIに代行させることでどのような価値創出が期待できるのか、を見定める必要がある。事例でも触れたが、たとえば「翌週予測」か「翌月予測」かなど、業務活動の種類によって価値のある時間軸粒度が異なるというような事情（ドメイン・ナレッジ）があるなら、それはこの段階で分別しておきたい。週別と月別では因果関係の構造が大きく異なり、AIが学習すべき因果データの内容や使用するアルゴリズムが異なるということは全く珍しくないからだ。

また、この粒度は、「組織経験知」の「組織」の範囲やくくりの大きさとも関連させながら議論し、イメージを醸成しておきたい。営業所単位なら他の営業所の経験知も含めて再現できるAIとなり、営業担当者個人単位でもまた然りである。そこに「立地特性の近い営業所でないと参考にならない」「天候の似ている地域が参考になる」などの経験知の

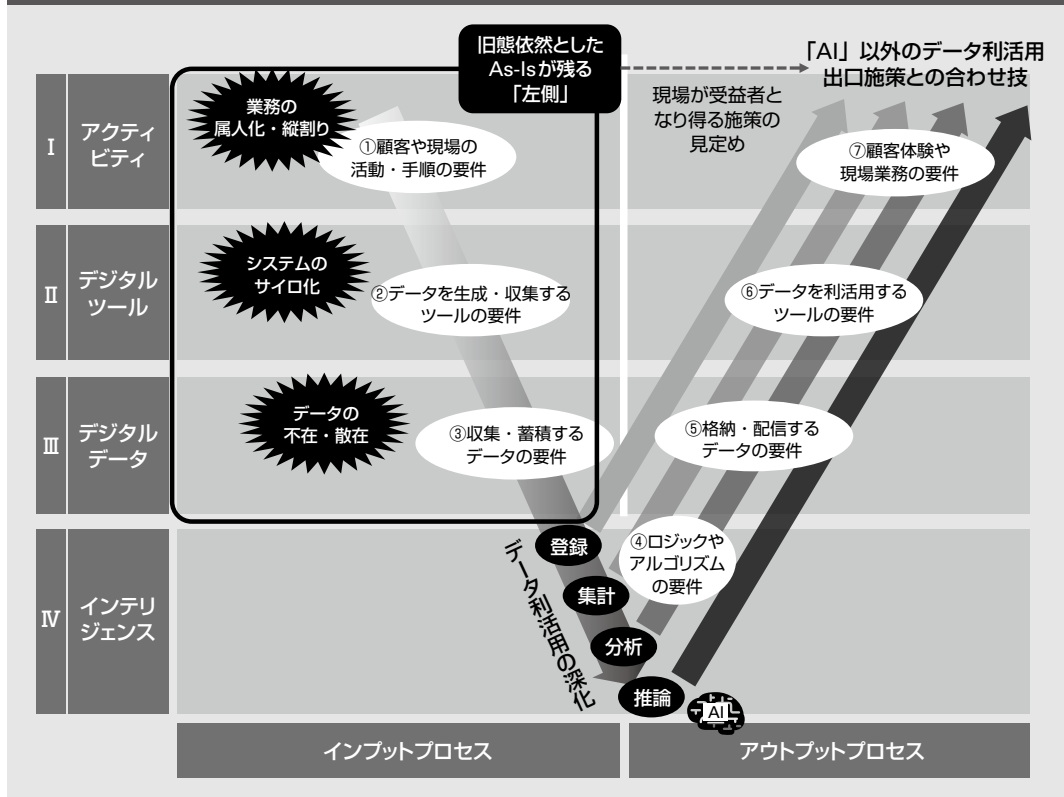
あり方が議論になれば、AI学習に必要な因果データのインプット要件や学習更新の頻度などの運用要件の設計に有効な情報ともなり、質の高いAI開発が可能となる。

(3) What?の範囲：組織経験知の再現には「4階層V字プロセス」の全体が必要

自社育成AIが精度の高い推論能力を獲得するには、因果関係データを豊富に学習させることが必要となるが、重たい「As-Is」を抱える企業ではそれを実現するのは簡単ではない。現場での貴重な業務経験が属人的・縦割りの行われ、システムも個別業務それぞれに「サイロ」のように構築され、結果としてデータが存在しないか無秩序に散在しているような状況も珍しくない。そのような状況でいきなり「組織経験知をAIで再現」という目標だけを掲げても実現性に乏しく、必要な問題意識を喚起することもできない。目標を達成するうえで避けては通れないチャレンジな状況がどこにあるのか、それがどの範囲にまで広がっているのか、その全体観について社内の共通認識を得ておくことも「What?」議論では重要なポイントとなる（図10）。

DX実現のためには、4階層の機能同士がV字状に連鎖していることが不可欠であり、「推論」というインテリジェンス層の最深部の機能の確立を目指す自社育成AI導入においては、より高度なV字プロセス連携が必要となる。最終的に実現したいことは「組織経験知」の再現だが、上記で触れた「業務の属人化・縦割り」「システムのサイロ化」「データの不在・散在」の状況はプロセス前半であるインプットプロセスが完全に未整備であり、このままではV字プロセス全体の成立

図10 4階層V字プロセス全体で描く「What?」



が不可能であることを意味している。

前節で触れたように、変革の対象となるすべての現場には「As-Is」とそれを維持したい動機が存在し、特に図10の左側インプットプロセスには旧態依然とした「As-Is」が複雑に張り巡らされているケースも多い。実際に外部の協力事業者に依存していて社内では業務実態すらよく分からない、ということもある。右側アウトプットプロセスの「What?」で華々しい未来像が語られる一方で、必ずしもAI導入による受益者とはならず、現状変更を強いられる現場関係者や外部事業者は、「左側」に多く存在する。経営として丁寧に向き合わなければならない「As-Is」はそこにある。

変革のためには、「Why?」に自問自答で

きる危機感の共有が大前提であり、加えてそれぞれが無関心・面従腹背に陥らずに何らかのインセンティブやモチベーションを見いだせるよう複合的な「What?」目標の設定が不可欠である。図10に示したようにインプットプロセスはAIのためだけにあるわけではなく、「登録」「集計」「分析」「推論」など、ほかのデータ利活用形態も含めてアウトプットプロセスの経路は数多くある。AI導入の受益者とならなかったとしても、旧態依然の「As-Is」にいる現場の業務パフォーマンスを上げるようなDXストーリーはほかにも必ずあるはずである（逆にないとおかしい）。「What?」の目標を複数組み合わせながら、それぞれの達成に向けた問題意識や当事者意識を喚起し成熟させることも、経営手腕の発

揮が期待される場所である。

3 How? : AI導入において、 現場は「ユーザー」ではなく 「メンター」

最後は「How? : どう変革を実現するのか?」である。強い危機感や変革構想まで共有できたところで、それをどのように推進していくべきか。AIという次世代テクノロジーだからこそその留意点や醸成すべき社内意識を確認しておこう。

AIに限らず、新たなツールやテクノロジーを導入する際には、ユーザーが適正な「期待値」が持てるかどうかは致命的に重要である。どれほど優れたテクノロジーでも、機能や効用が期待とずれていれば「期待外れ」となり、使われなくなる。特に運用開始後に期待外れが起きると、実務上のトラブルに至り、現場は状況把握や関係者フォローに追われるなど、大きなフラストレーションとなる。最悪の場合「あの手のものはもう二度とごめんだ」などと深刻なテクノロジー・アレルギーとなって後々まで尾を引くこともある。

特にAIの場合、現場にとって未知で異質な道具であるため、期待値の設定やその合意形成はより難しいものとなる。「組織経験知を学習・再現させる」という今まで機械に任せなかったことのない役割を担う存在に対して、漠然と従来のITシステムと同じように「システム部門が作り、現場がそれを使う」という構図で待ち構えられると、前章の事例のような期待値のずれが発生し、軌道修正も難しくなる。このような状況を回避するためには、「How?」議論の提起の仕方に工夫が必要となる。掲題の「AI導入において、現場は『ユ

ーザー』ではなく『メンター』』であるというのは、AI導入現場のあるべき立ち位置を提起するもので、AIというテクノロジーに対する期待値を適正化し、それと向き合う当事者意識を引き出すためのシンプルで効果の高い方法である。メンターとは「よき相談相手・指導者」といった意味である。つまり現場は与えられたAIをただ「使う」のではなく、「育てられるか」、そして育てた結果としてAIに仕事を「任せられるか」が問われる立場にあることを投げかけるものである。これはAIを情緒的に擬人化しているわけではなく、AIが実装された現場がそこから価値を引き出すために必要な管理方針やオペレーション要件を具体的に設計するための、実務的な「How?」提起の方法論である。

以降に「育てられるか」「任せられるか」の2点について補足説明する。

(1) AIを「育てられるか」

これまで論じてきたように、自社育成AIから引き出すべき能力は「組織の経験知の再現」である。AIに価値ある仕事をさせるためには、どのような経験知を再現させたいのかを業務部門が主体的に考え、その考えが反映されているような因果関係データをAIに与え続けることが基本となる。

AIが良質なデータを学習し、ビジネスに利用できる推論精度を確立できれば、その後しばらくは「よい判断→よい結果」の因果サイクルの継続をAIに任せておける。一方、突発的な環境変化、もしくは潮目の移り変わりなどによって実際の結果に変調が現れ、過去の因果関係をそのまま再現させられない状況になった場合は、人間が介入する。新たな

組織経験知として習得するまで人間が介入するケースもあれば、逆に単発的なイレギュラー介入として学習データから除外するケースもある。これが「育てる」の実務イメージの一例である。

実際のところ、AIの「精度が低い」「感度が鈍い」とシステム部門やデータサイエンス部門に相談しても、学習しているデータの質が悪ければ、技術的に対応できることは限られている。「AIがよい仕事をするには、まずは見習うべき手本を自分たちが示す」といった当事者意識があれば、「AIはチャレンジしない」「AIは勝手に賢くなる」という誤解や、「鈍いAIを何とかしてくれ」などの他責思考を未然に防げる。また、仮にAIの推論精度に不調を来しても、関係部門がそれぞれの責任感やドメイン・ナレッジをもって建設的に対応を協議することができる。これは「How?」としてメンターの自覚を問うことの重大な効用の一つである。

(2) AIに仕事を「任せられるか」

事例にも登場したとおり、AIが健全に育ったとしても、その仕事（推論結果）を人間が信じて活用できるかはまた別の問題である。AIの帰納的推論には人間の理解が及ばない暗黙知的な過程を含むが、それと引き換えに応用性や柔軟性、そして不安定性を備えており、これは人間の経験的判断とも特性がよく似ている。人間はこの経験的判断を他人と分担したり委譲したりすることで組織を成り立たせている一方で、この判断能力を人格から切り離して機械化するということが仕事や組織にとってどういう意味を持つのか、現時点では多くの現場や企業においてまだ感覚

的な理解が追いついていない状況ともいえる。

前章の「ケース⑥」の現場で起きていたことはまさに、「感覚的な理解が追いついていない」という状況であった。ここでその経緯を少し補足説明しておこう。

活動当初はAIの役割を従来のITシステムと同様にイメージし、ユーザー部門は「これくらいはできないと現場で使えない」という状況であった。その後、PoCを経て現場実装が近づき、数多くの現場関係者や顧客への影響を具体的にイメージできるようになると、一転して「そこまでやらせて本当に大丈夫なのか」という不安が生じ始めた。そしてAIの推論結果に対する微妙な違和感について、一つひとつデータサイエンス部門に質問を投げかけ、推論の根拠の確認が行われていくが、聞けば聞くほどリスクな想像がエスカレートしてゆく。最終的には、機械学習アルゴリズムの専門知識を駆使しても答えようがない「決めの問題」にまで問答が及んでしまい、「これでは根拠を聞かれたら説明ができない」との評価により断念に至ってしまった。

ちなみに、代理店への発注指導に長けた現場ベテラン社員に、問答の例として「欠品許容率5%という基準値の妥当性を、どう説明したら代理店が納得してくれるか」を尋ねると、苦笑しながら「そんな基準値、ほとんどの代理店は知らない。設定根拠を追求されることもない」とのこと。

AI導入における「How?」意識の成熟が不足していると、このようなことも起き得るのである。従来のITシステムと同様の「ユーザー意識」に基づいて過大な期待値と業務要求を示し、その後AIシステムが担う機能

や役割の特異性を徐々に認識する中で、自ら示した業務要求レベルでのAI活用はオペレーション・ミスによるリスクが大きすぎるとの不安感を抑制できなくなってしまった。当初からメンター意識を持ち、任せた仕事でAIがミスしても自分たちで業務リカバリーが可能な範囲に業務要求を収めていれば、結論は違っていた可能性はある。

また、ユーザー意識のままだと、「任せたことがなかった仕事をやらせてみる」という、メンターに求められるような「任せる勇氣」も喚起できず、逆に相手が人間なら求められないようなレベルの判断根拠を「形式知的」な説明が得られるまで延々と追求する意識になりがちである。

人間が、ルールやマニュアルで言語化された形式知的な思考を経由せずに判断している仕事は実際には少なくない。そのような暗黙知的に対応できる仕事の種類が増えることを、むしろ「成長」と呼んで、喜んだり褒めたりするものだ。「経験的な思考・判断能力」をもつ次世代テクノロジーを、新たな知的労働力として組織に受け入れられるのか、健全な期待値とメンター意識の成熟を促すような論点として提起したいところである。

(3) PoCで検証すべきは

現場のメンター意識の確立

AIという未知で異質な能力を導入するうえで、社内の問題意識・当事者意識がいかに重要か、それをいかに成熟させるかについて、「Why? →What? →How?」の順で論じてきた。「How?」においては「育てられるか」「任せられるか」というメンター意識の重要性に触れたが、最後にその確立のタイ

ミングを確認しておこう。その観点で重要となるのがPoCの位置づけの再考である。

一般的にPoCの目的は技術・業務の観点からの実現可能性の検証に重点が置かれることが多い。またROI (Return on Investment : 投資対効果) 推計のために経済的効果の原単位を測定する機会としても活用されているだろう。それらに「メンタリング・オペレーションの確立」という視点を検証事項として加えることを強く推奨する。自社育成AI導入を現場主導で牽引し、新たな戦力として受け入れるメンター意識が備わり、そこにAIを「育てる」「任せる」ことで価値を実現するまでの実務オペレーションが伴っている状態をこの期間に確立したい。

技術やROIの検証結果がどれほど良好でも、メンタリング・オペレーションが確立していなければ、その後どこかのタイミングで必ず活動は停滞する。AIが順調に仕事をしている間はよいが、推論結果に違和感が生じた途端に現場が動揺し始め、活動全体が評論や他責によってネガティブな雰囲気になる。現時点では常時・永遠に精度の高い推論をし続けるAIなど存在しない。世の中はVUCA^{※3}に動き続け、技術も常に進化しており、世の中が変わればAIも進化する必要がある。機械学習アルゴリズムの最新研究状況のモニタリングや更新はデータサイエンス部門が担うべき仕事だが、日常的なAIの能力維持・育成はビジネス部門の現場にしかできない仕事であり、それこそがメンタリングである。

PoC検証を経て活動の継続・展開に経営からの承認が得られれば、投資金額や利害関係者の範囲はさらに膨らむことになる。経営にとって大きなダメージとなる展開後の停滞・

混乱を回避する対策を打つことは、PoC本来の目的でもある。「Why?→What?→How?」まで社内意識が成熟したら、後は「Do!（実行）」あるのみだ。その前の総仕上げとして、PoCを通じて問題意識・当事者意識の最終形態である「メンター意識」の状況を経営の目線から見極め、それを体現する実務の確立に向けた論点と目標を提示したい。

V おわりに：「思考技術」を 駆使して議論と意識を引き出す

本稿執筆のきっかけは、具体的な成果を実現しているDX企業は、他企業と比べて「議論の質」と「問題意識の成熟度」に顕著な違いがあり、それが経営のリーダーシップによって引き出されているという共通した構図が広く参考になると感じたことである。

多くのDXでは「範囲が広い、変化が早い、問題が根深い」という状況と対峙することになる。そのような中でも社内を混乱・迷走させないようなDXリーダーシップを発揮するためには、自分の頭の中や他人とのコミュニケーションにおいて、状況解釈から論点抽出、合意形成までを精度高く効率的に実施しなければならない。このような知的生産活動には、その品質と継続性を担保するための機構を備えておく必要があり、それが本稿で紹介したフレームワークやその運用テクニックから成る「思考技術」である。

前編ではそれを「議論の質」という視点から整理した「4階層V字モデル」「DX基本構想」などのフレームワークを紹介した。この後編では、自社育成AIのような、より変革難易度の高い深層DXに挑むときにあらた

めて問われることになる「問題意識の成熟度」という視点から、それに段階的に応える「Why?→What?→How?」について、苦戦事例とともに考察した。

前編で紹介した国際経営開発研究所（IMD）の「世界デジタル競争力ランキング2022」では、「企業の俊敏性」の項目で日本は世界最下位^{※4}であることが示されたが、これは日本企業が怠惰であることを示しているわけではなく、これまで企業成長を支えてきた「強い現場」と「強い品質と顧客満足へのこだわり」が長い歴史の中で積み上げてきた「As-Is」のもたらす強い副作用と捉える方が釈然とする。俊敏に動きたくても動けない、それぞれにとっての合理的な理由があり、DXを機にその解きほぐしを試みても、感情論をオブラートに包んだ空中戦になりがちだ。だからこそ「議論の質」と「問題意識の成熟」を丁寧にコントロールすることが不可欠であり、それぞれが真摯に向き合わなければならない課題と目標がどこにあるのか、思考技術を駆使して見極め、それを指し示すような経営リーダーシップの発揮が期待される場所である。

昨今はAIといえばChatGPTや生成AIの話題でもちきりである。本稿では組織経験知で競合差別化を目指す「自社育成AI」を議論の対象としたため、現段階で組織経験知と機能的な関連性の薄い生成AIにはあまり触れていない。しかし、その進歩は周辺技術の追随を含めて驚くほど速い。生成AIについては、文章作成やチャットなど部分的・単発的な便利ツールとしての用途から、自社オリジナルの経験知データを推論能力に組み込み、自社競争力の強化に役立てようとするユース

ケースも少しずつ出てきており、実際にNRIがかかわる導入支援・意見交換の機会も日に日に増えている。

今後、その「知能」の持つ特性とそれに基づく実務的な課題が体系的に見えてきたタイミングで、アップデートされた思考技術とともに紹介することとしたい。

注

1 LLM (Large Language Model: 大規模言語モデル) は、言葉を多次元空間上のベクトルとして扱い、大量の文書データを基にディープラーニング (深層機械学習) を用いてコンピュータに自然言語処理の学習をさせる技術。このモデルは、言葉同士の意味の類似性だけでなく、文脈の理解や文章の生成、質問応答などの多岐にわたるタスクを実行する能力を持つ。ChatGPTはLLMの一種で、GPT (Generative Pretrained Transformer: 大量のテキストデータで事前学習されたトランスフォーマー型のモデル) を搭

載したチャットボットである

- 2 XAI (eXplainable AI: 説明可能なAI) やSHAP (SHapley Additive exPlanations) など、特徴量 (原因データ) の相対的な影響度合いなどを知ることによってAIの推論結果に対する説明性や解釈性を得ようとする技術開発や手法研究もされているが、因果関係が解析的に得られるわけではない
- 3 Volatility (変動性)・Uncertainty (不確実性)・Complexity (複雑性)・Ambiguity (曖昧性) の頭文字を取った、予測が難しい現代社会の性質を表した造語
- 4 <https://static.poder360.com.br/2022/09/Digital-Ranking-IMD-2022.pdf>

著者

福原英晃 (ふくはらひであき)

野村総合研究所 (NRI) コンサルティング事業本部
パートナー

専門はDX業務改革、SCM改革、コスト構造改革、テクノロジー導入を契機としたオペレーション変革など