

AIのビジネス適用時に直面する壁とAI民主化に必要なもの

多胡 篤 (たご あつし)
向 正道 (むかい まさみち)
日鉄ソリューションズ株式会社

1. はじめに

近年 Deep Learning をはじめとする AI ブームにより、世界的に大企業の多くが AI 導入を検討し、ビジネスへの AI 適用を試みている [1] なかで、国内では約 47% の AI プロジェクトが実証実験 (PoC) に進まない [2] など、ビジネス適用や全社的な活用に至るケースは限られているともいわれています。

一方で、企業や個人が AI 技術を容易に利用できる、いわゆる「AI 民主化」を実現するプラットフォームやソフトウェアの登場により、ビジネスの現場における AI 活用の敷居は確実に下がってきています。日鉄ソリューションズ (以下当社) においても、AI 普及の波に乗り、2016 年より DataRobot 社と代理店契約を締結し、機械学習自動化ソリューションの販売を行っています。そして、さまざまな業種の企業の AI 民主化をご支援させて頂いております。

しかし、そのような形で AI 活用の敷居は下がったように思える一方で、多くの企業が依然として AI 導入に困難な課題を抱えているのも事実です。

本稿では、当社がお客様である企業をご支援する活動を通じて得られた、AI をビジネス適用するプロセスで発生する代表的な壁 (課題) を示し、真の AI 民主化を実現するためにおさえておくべきポイントを述べさせていただきます。

2. AI 民主化とは

本稿で言及する「AI」は、現状においてビジネス上の実用段階にある、「特定のタスクにおいて限定された知能によって問題解決や推論を行う『特化型 AI』」[3] のことを指し示すこととします。

従来、AI を活用できるのはデータサイエンスやプログラミングのスキルを有する一部のデータサイ

エンティストや研究者に限られていました。しかし近年、データサイエンスの深い知識がなくともノンプログラミングで AI や機械学習を利用できるプラットフォームやソフトウェアが出現してきました。例えば DataRobot 社が提供するプラットフォームや Google 社が提供する Cloud AutoML はその一例です。

本稿ではそのような仕組みを活用しながら、企業における非データサイエンティスト人材や現場担当者などの誰もが「AI を活用して全社的にビジネス課題を解決できるようになるまでのプロセスまたはその現象」のことを AI 民主化と呼んでいます。

3. AI をビジネス適用するプロセス

前項にて「AI を活用して全社的にビジネス課題を解決できるようになるまでのプロセスまたはその現象」を AI 民主化と呼びました。ここではさらに、AI をビジネス適用し、ビジネス課題を解決するプロセスがどのようなものかについて述べます。

AI をビジネス適用するプロセスは大きく以下の 4 つのフェーズ [4] でとらえることができ、各フェーズにおいて以下のような作業が必要になります。

フェーズ 1. テーマ設定

- AI/機械学習のアプローチで解決可能な業務課題の発見と達成目標の定義。
- 得られるビジネスインパクト (ROI) の算出。
- ステークホルダー/スポンサーとの合意。
- AI/機械学習問題への定式化及び予測ターゲットの定義。

フェーズ 2. データ準備

- 業務課題や業務ノウハウをデータ表現するうえで必要なデータソースの洗い出し。

- ・取得可否の調査と方法の整理、アクセスコスト（リードタイム/調整/調達コスト）見積もり。
- ・データ利用のための社内関連部門との調整。
- ・データの調達と統合/加工。

フェーズ3. AIモデル開発

- ・機械学習モデルの作成。
- ・精度向上のためのさらなるデータ加工や新たなデータ取得（特徴量エンジニアリング）。
- ・精度向上のためのアルゴリズムの選択やアンサンブルの検討/ハイパーパラメーターチューニング。
- ・モデルの安定性や汎化性能を高めるためのバリデーションスキームの検討 [5]。

フェーズ4. 業務適用

- ・作成したモデルの業務現場担当者への説明とこれまでの経験値との整合性の確認。
- ・業務上の意思決定とアクションへの有用性の確認。
- ・ROI効果測定（A/Bテスト等）の設計と実行。
- ・モデルデプロイ、運用フロー、システム実装方式（アプリ開発等）の設計と実装。
- ・継続的なモデルの精度監視、アクセス監視、トレーサビリティ管理フローの設計。

4. 各プロセスで直面する壁

前述のとおり、AIのビジネス適用は複数のプロセスを経る必要があります。そしてそれぞれのプロセスにおいて乗り越えるべき壁（課題）が存在します。

企業におけるAIビジネス適用を実現するためには、これらの壁の存在を事前に認識し、対策を講じる必要があります。

本項目では、各プロセスにおいて発生しうる代表的な壁とそれを乗り越えるためにおさえるべきポイントを整理します [6]。

4.1 「テーマ設定」フェーズ

テーマ設定フェーズは、AIのビジネス適用プロセスの中でも最も重要なフェーズです。なぜならばここで描いた効果目標と改善イメージが100%達成状態の理想の姿であり、その後のフェーズでは「さ

らなる減点をいかに抑えられるか」という減点法の戦いになるためです。

この初期段階で実現可能性の視点から適切なAIによる解決テーマをピックアップし、その期待効果をマネジメントやステークホルダーと合意し、プロジェクト実行への予算化と合意をとりつけることが必要です。

本フェーズで注力して検討すべき代表的な以下3つのポイントを取り上げます。

- ①ビジネス価値
- ②実現可能性
- ③打ち手や意思決定への接続性

①ビジネス価値

取り扱うビジネステーマがどれだけインパクトを生み出すかを定量化することは、AI活用のビジネス価値をマネジメントに認めてもらうために最も重要です。

実行組織のミッションやKPIとしてAI活用のROIを求められているケースはもちろんのこと、特にそのようなビジネス上のコミットメントを求められていない実行組織においてもビジネスインパクトを最優先してテーマ選定を行う必要があります。

なぜならば、AIの価値はビジネス貢献そのものであり、継続的にAI運用にかかる各種コスト（プラットフォーム、人材、教育、データ調達コスト等）を回収しながら、プロフィットセンターとしてどのようにビジネス貢献できるのか、ということを通じてのステークホルダーにわかりやすく説明し、周囲を巻き込んで実行する必要があるからです。

業務としての継続性と必然性を確保するためにも、実業務へのビジネスインパクトと結びつけた議論を常に行うことが必要です。

なるべく高いビジネスインパクトにつながるテーマを選び出すには、自社の主軸となる事業ドメインに関わるサービス、商品、あるいはプロセスを対象とすることが有用です。

例えば、商品の需要予測テーマであれば自社売上げや業界シェアの高い商品から予測モデルを作成する、製造プロセスにおける不良要因特定による歩留まり向上であれば製造原価や関わる人件費の高いプロダクトの製造ラインについての要因モデルを作成

する、という形です。

ただし、自社の主軸となる事業ドメインは伝統的に業務や管理の仕組みが作り上げられていることが多く、変革へのコストやリスクが高い場合があります。そのような場合は敢えて、その周辺で難易度が高いために仕組み化できておらず放置されてきた課題や、難易度が高くなくとも仕組み化の手が未だ届いていない課題から着手し、小さな成功と信頼を積み上げるといったアプローチをとることもあります。

変革マネジメントにおいてはまずは小さくとも最初の成功を早期に創出し、それを積み上げ、拡大していくことが重要です。

また、ビジネスインパクトはその大きさと同様に、極力定量化し要素分解して語ることが必要です。例えば、インベストメント削減の視点であれば、仕入れや調達に関わる金額や機会損失の金額、投下する時間、スタッフ人数、作業頻度など、どのKPIを調整できてどのくらい減らせるか、リターン向上の視点であれば顧客の購入単価、購入頻度、生涯購入金額（LTV）のどこに作用させられるかという視点で、収益を構成する要素を分解してビジネスインパクトを分析する必要があります。

ビジネスインパクトをはかるうえで上位のKGI（例えば売上）として重要視されている指標は、複数のKPIから構成されているケースがあります。インパクトを算出する場合にはKGIを構成する重要なKPIに優先順位をつけ、どのKPIがAI/機械学習で説明可能かを判断し、他のKPIが固定されていると仮定した場合に該当のKPIを改善させることでどのくらいKGIへのインパクトが期待できるかを確認することが理想です。

時にKPIは各ストラテジックビジネスユニット（以下SBU）ごとに恣意的に設定されていることも多いのですが、各SBUのKPIがどのようにKGIへ事業貢献しているかをモデル化するというのは横断的なAI推進組織ならではの可能な視点であり、求められるアプローチでもあります。

また、必ずしも定量化できなくともインパクトの大きいものも存在します。例えばブランドイメージ棄損防止やコンプライアンス遵守などのリスクマネジメントテーマなどがそれに相当します。そのような場合は現状それらの防止策にかけている総予算に対する費用対効果という見方も考えられます。

②実現可能性

AI、機械学習ではインプットデータ（説明変数）とアウトプットデータ（予測ターゲットやKPI）が必要になります。ですので、何はともあれ解決したいビジネス課題が、存在するデータと対応づけられるのか、かつ今後も十分なデータを取得し続けられるのか、という視点をもつことが大切です。

例えば、法人向け営業業務の効率化において、現時点における受注可能性の高い営業先を予測するというテーマの場合に、そもそも受注データしか存在しておらず失注データが存在しない状態であれば予測モデルを作成することはできません。

また、仮にアンケートデータのように取得に手間と時間がかかるデータの場合は、仮に予測モデルを作成できたとしても継続的にアンケートを収集し続けるコストがかかり、予測モデルの業務運用が難しいということも起こりえます。

また、機械学習問題への定式化が可能であるかという視点からも実現性を考える必要があります。

ここでは「ビジネス目的」と「扱うデータ」と、「AI要素技術」を適切に組み合わせる考え方が有用です。これらの組み合わせの視点を図1に整理します。

上記に示すようにAIの要素技術を用いて解ける問題はその組み合わせを含めるとさまざまなタイプがありますが、特化型AIの特性とビジネスインパクトを生み出し要因を明らかにするというビジネス適用を中心に考えた場合、過去実績データをもとに推定するレガシーな教師あり機械学習による予測（回帰/分類）及び時系列の予測（回帰/分類）モデルが使用されるケースがまだまだ多いのが現状です。

「Deep Learningを使わなければならない」というような要素技術起点の発想ではなく、あくまでも



図1 「ビジネス目的」「取り扱ったデータ」「AI要素技術」の組み合わせ

ビジネス目的からブレイクダウンするという視点を持ち、解決したいビジネス課題をターゲット化し、さらにはそのターゲットをデータとAIの要素技術を用いて予測する問題へと定式化する、というアプローチが必要になります。

③打ち手や意思決定への接続性

重要なKPIや異常を予測する機械学習モデルが完成しても、それをもとにビジネスの意思決定やアクションに接続できなければ意味がありません。そのためにはテーマ設定時に以下の2点を考慮する必要があります。

1つめは、機械学習で予測するターゲットまでのタイムライン（予測距離）を、業務的に意味があるかを考慮しながら設定することです。

例えば社員の退職予測をする予測モデルであれば、1ヵ月後に退職するかどうかを予測できても、そのころにはほぼ退職の意思は決まっていますので手の打ちようがありません。少なくとも半年前にその予兆を検知できるモデルを作成したほうが望ましいでしょう。一方で予測する未来が先であればあるほど予測の難易度はあがります。予測する時点で手に入るデータを用いて、どこまで先を予測することが可能なのかという技術視点と、どこまで先を予測できれば業務的に有意義なのか、のビジネス視点の両輪で考慮する必要があります。

2つめは、コントローラブルなインプットデータ（説明変数）でモデルを作成することです。前述の退職予測の例でいえば、前職の経歴や年齢、所属部署などのアンコントローラブルな属性データだけでモデルを作成してしまっただけでは、たとえ高い予測精度のモデルを作成し、退職の要因が分かったとしても打ち手につなげることができず、ビジネス価値を生み出せないでしょう。

以上に述べたとおり、テーマ設定フェーズではビジネス価値、実現可能性、打ち手や意思決定への接続性という視点を重視して進める必要があります。

4.2 「データ準備」フェーズ

使用するデータは構築する予測モデルの精度に大きく影響します。また、データ準備や加工にかかるコストを含めてROIを考慮する必要があります。

本フェーズで注力して検討すべき代表的な以下3つのポイントを取り上げます。

- ①データの質と量
- ②データの調達コスト
- ③目的視点のデータ調達

①データの質と量

予測モデル作成にはある程度のレコード数を確保する必要があります。お客様との機械学習プロジェクトの経験上、全体では数千レコード、最低でも数百レコード、分類問題であれば予測ターゲット（正例）となるサンプルが負例に対して10%程度、絶対値でも最低100程度は得られるテーマを設定できることが望ましいです [7]。

例えば、月次粒度のデータであれば週次や日時の粒度にしてデータ量を増やす、商品の売上げ数量であれば店舗やチャネル別の売上げデータにするなど、予測ターゲットの粒度を詳細化することでレコード数を確保することが有用な場合もあります。

また、使用するデータに偏りが生じていないか（もしくは恣意的なサンプリングになっていないか）を考慮する必要もあります。

例えば偏ったサンプルのアンケートデータや、恣意的な思惑のうえに操作された営業履歴データ、前提条件の偏った実験データ、特殊なイベントや災害のあった年の例年とは異なる時系列売上げデータなど、予測モデルを作成した時に使用した実績データと実際に予測を運用する際に使用するデータとで分布が異なる可能性のあるデータはモデルそのものの品質と信頼性を低下させます。

②データの調達コスト

データ分析用のDWHやマートが分析基盤としてすでに構築されている場合は問題ないですが、通常は必要なデータは社内の各システムに散らばっています。データの保管形式と保持期間は各システムの目的に応じて最適化されているため、必ずしも予測モデル作成に適した形では存在していません。多くのシステムは構造化データとして保持されていますが、AI/機械学習で使用するデータは例えば人事採用エントリーシートのテキストデータ、コールセンターの対応履歴のテキストデータ、不良品の写真

データなど、非構造化データも対象になるケースがあります。それらのデータがどのシステムにどのような形式で保管されているかを調査する必要があります。

また、システム間のデータの流れを調査することも必要です。なぜならば源流のシステムから連携された同一のデータが各システムにて異なる形式で存在していたり、ある処理タイミングで必要な情報が消失しているケースも考えられるからです。分析の目的によってどのシステムに存在するデータ形式と項目がふさわしいのか、そこへ連携されるタイミングや粒度は作成する予測モデルにインプットするデータの要件を満たすのかの調査を行い、かつデータ取得の承認までをとりつける社内調整プロセスが必要で

す。データ調達にかかるコストは、「調達に必要な時間的なリードタイム」「抽出依頼する運用コスト」「加工にかかるコスト」が存在します。AI活用のROIを証明できるようになるまでは、AI活用に最適化したデータの保管や自動連係が可能になるようなシステム改修は社内説得が難しい場合が多く、AI活用におけるROIはそのデータの調達加工にかかわる運用コストを含めて設計しておく必要があります。

データ調達は社内の組織体制とも密接です。ソースデータ調査を行った場合は各データごとに保管の主管担当部門、担当者名、承認を得るためのキーマン、保管形式、更新頻度、保持期限などを整理一覧化し、常にアップデートを行っておくことでAI運用フェーズにおいてデータ取得が不可能になるリスクに備えることにもつながります。

③目的視点のデータ調達

AIのビジネス適用を考える場合は「社内（時には部内）で今現在入手可能なデータで何ができるか」という視点から考えがちですが、ビジネス価値へつなげる精度の高い予測モデルを実現するという点では、予測するビジネス目的からどのようなデータがあれば良いのだろうかという視点を持つことが有用です。

例えば、実業務で中古車の価格予測を行う際に外部サイトの市場の小売価格を参考にしているならば、その予測モデル作成においても、インプット

データとして外部から調達した小売り価格データをクローリングして使用するのが望ましいですし、店舗の売上げの推移に天候情報を参考にしているならばより精緻な天候予測データを専門機関から調達することで予測精度を向上できる可能性があります。

さらに、目的視点のデータ調達において注意しなくてはならないのは、目的を「予測」にするのか、「要因分析」にするかで使用するべきデータも異なってくるという点です。例えばSNSの口コミの爆発が売上げに影響した場合、過去の売上げ要因を分析するためのモデルにそのようなデータを使用することはできますが、未来の売上げを予測する目的の場合は、そもそも口コミが爆発するかどうかは予測時点で未知であるため、モデル作成時にインプットデータとして含めることは適切ではなく、予測をする時点で入手可能な、（予測時点で）既知なデータのみで予測モデルを作成する必要があります。

以上あげたとおり、データ準備フェーズではデータの質と量、データの調達コスト、目的視点のデータ調達というポイントを重視して進める必要があります。初期のテーマ検討フェーズの時点で、各テーマごとに、データ調達フェーズの視点までを考慮して検討する必要があります。

4.3 「AIモデル開発」フェーズ

従来はモデリングにおいては高度なデータサイエンスの知識と職人的なノウハウ、プログラミングの知識が必要でしたが、近年ではモデリングをノンプログラミングで実施可能にしたり、これまで精度を高めるために行われてきた高度な処理やノウハウを自動化するAutoML [8] というカテゴリのソフトウェアやプラットフォームが登場しています。

AI民主化の兆候が近年最もわかりやすく表れはじめているのがこのモデリングフェーズの効率化であるとも言えます。弊社が代理店として販売しているDataRobotのプラットフォームにおいても、インプットデータと解く問題に応じたアルゴリズムの選択、アルゴリズムに応じたデータの前処理の選択、複数のアルゴリズムでの精度検証、アンサンブルモデルの作成、及び各種インサイトの可視化及びデプロイまでが自動化されており、モデリングフェーズを劇的に効率化させることが可能です。

しかしここにおいても考慮すべきいくつかの課題とポイントが残されています。本フェーズで注力して検討すべき代表的な以下2つのポイントを取り上げます。

①特徴量エンジニアリングによる精度向上

②リーケージ回避による汎化性能の向上

①特徴量エンジニアリングによる精度向上

機械学習モデルの作成にはインプットデータが必要ですが、特にモデルの精度を向上させることを目的としたインプットデータの加工のことを「特徴量エンジニアリング」と呼びます。

特徴量エンジニアリングはインプットデータの列同士を加減乗除するというシンプルなものもありますが、特にドメイン知識をもとにしたデータ加工で精度を向上させる特徴量エンジニアリングが精度向上には有効です。

「ドメイン知識」とは業務の現場担当がこれまでの業務経験の積み重ねの中で獲得した、あるいは継承されてきたノウハウや集合知を指します。このドメイン知識をインプットデータで表現することはモデルの精度向上には不可欠であると同時に、まさに業務に依存するため完全な自動化や一般化が難しい部分のひとつでもあります。

例えば、サービス業における顧客の離脱予測において、過去の購入頻度をインプットとする場合に過去どのくらいの期間までの頻度をさかのぼってカウントすると離脱予測のシグナルとして有用なのか、レストランの需要予測において気温の絶対値そのものではなく、湿度や風速をもとにした体感気温 [9] が需要を左右するであろう、など現場の肌感覚をデータでどこまで表現できるかという、ドメイン知識とある種職人芸的な側面も持ち合わせています。

実際に当社のお客様との精度改善のディスカッションにおいてもここに多くの時間を割きます。特徴量エンジニアリングはデータサイエンスの専門家とビジネスの専門家の共同作業が要求される、精度向上のために最も重要なプロセスとも言えます。

②リーケージ回避による汎化性能の向上

機械学習モデルを作成するうえで予測モデルの精度指標を向上させることが大前提ですが、逆に精

度が良すぎるモデルができてしまうことに対する配慮も必要です。精度が良すぎる場合は、本来ならば目的変数にだけあるべき情報がインプットするデータ内に漏れ出ている可能性があるからです。そのような状態のことをリーケージと呼びます。

リーケージが生じると機械学習モデルを作成するプロセスでは高い精度を発揮するが、実際の予測業務へ適用した際に極端に精度が低下するということが起こりえます。

リーケージの原因としては説明変数（TABLEデータの列）方向にリークするケースと、検証データ（TABLEデータの行）方向にリークするケースの2つがあります。

列方向にリークするケースの代表例は説明変数に未来の情報が含まれているケースです。例えば患者ごとにある種類の癌の罹患予測を行う場合の説明変数として該当の癌の手術履歴が含まれている、ある消費者による商品購入における商品のクロスセルを予測する場合の説明変数として予測時点における商品の購入点数がすでに含まれてる、などです。このような場合は直接的あるいは間接的にでも未来の情報を与えてしまうような説明変数を除去してモデルを作成する必要があります。

行方向にリークするケースの代表例は機械学習時の検証データに学習データが含まれているケース [10] です。

例えば、社員の退職を予測するモデルを構築する場合に学習データと検証データに同一な人物のレコードが含まれている、製造ラインの不良品を予測するモデルを構築する場合に学習データと検証データに同一のロットのレコードが含まれている、というデータスプリットが発生すると、前者のケースでは人の違い、後者のケースではロットの違い、という形で、意図したインプットデータによらない非常にシンプルなるルールをもとにした判別モデルが作成されてしまい、不当に精度が高く、実業務上意味をもたないモデルが作成されることがあります。

また、行方向のリークは時系列性を持つモデリングにおいても頻繁に起こりえます。例えば機械学習のアプローチで時系列予測モデルを構築する際に、レコードの前後関係を無視してランダムにクロスバリデーションを行い、学習データ側に未来のデータが含まれ、検証データ側に過去のデータが含まれる

ようなスプリットが発生した場合、未来の情報を使用して学習し、過去のデータで検証しているため、不当に精度が高いモデルが作成されるというケースが起こりえます。時系列性を考慮する場合は、必ず過去のデータをもとに学習し、未来のデータで検証するという前後関係を意識したバリデーションスキームへの配慮が必要になります。

列方向のリークは説明変数と目的変数の相関関係である程度自動的に検知することも可能ですが、強い相関があるから必ずしもリークが起きているとは限りません。リーク判断にはデータの作成方法の技術的視点とドメイン知識をもとにしたビジネス的な視点からの両方からの注意が必要になり、非常に難しくかつ高頻度で発生する課題です。

モデリングフェーズにおいては AutoML や特微量エンジニアリングにより精度を向上させる取組みを行うと同時に、リークを回避して未知のデータに対しても安定した精度を発揮できる汎化性を求める取組みの両方が必要になります。

そして、このプロセスはデータサイエンスの専門家とドメイン知識に詳しい現場のビジネスの専門家の共同作業が最も必要になるプロセスでもあり、AI のビジネス適用において、この両者の共同作業をいかに効果的に実施するかが成功への鍵となります。

4.4 「業務適用」フェーズ

作成した機械学習モデルを実際の業務に適用するには、既存業務プロセスへの変更が生じるため、必然的に関連する利害関係者が増えることもあり、慎重に進める必要があります。最も優先すべきは現場の業務担当者にその有用性を納得したうえで受け入れてもらうこと、次に仕組み化を実現するうえで適切な関係者を巻き込むことです。この部分のコミュニケーションを失敗すると、せっかく作成した予測モデルを業務に適用することができないため、細心の注意が必要です。

本フェーズで注力して検討すべき代表的な以下3つのポイントを取り上げます。

- ①現場業務担当の受容
- ②ステークホルダーの巻き込み
- ③継続的な改善を考慮した運用設計

①現場業務担当の受容

既存の業務担当が納得感をもって機械学習モデルの利用を受け入れなければ業務には定着しません。そのため代表的なポイントとして以下の4点をあげます。

1. 現場の業務を奪わない
2. 現場の勘や経験とすりあわせる
3. 既存業務と並行して導入する
4. AI 受益者に応じたインターフェース (UX)

1つめは「既存の業務を奪うもの」ではなく「既存の業務や意思決定を手助けするもの」もしくは「効率化によりさらに重要な業務への注力を手助けするもの」という伝え方をすることです。既存業務担当者の存在意義を最大限に尊重し、AI 活用への心理的ハードルを上げないことが最優先です。

2つめは作成した機械学習モデルから得られるインサイトや予測の根拠を伝え、これまでの知見と共感を得られる部分を明示化すると同時にこれまで気づけなかった新たな発見を提示することでその有用性を認識してもらうことです。プロジェクトの早い段階から業務担当者にも参画してもらい、テーマ設定や特微量エンジニアリングの議論に参加してもらう共同作業を通じてその有用性への理解や納得度を深めてもらうことが必要です。

3つめは既存の業務と並行導入することからはじめることです。既存業務はすでにサービス提供の仕組みとして事業の中に組み込まれており、エンドユーザーへのサービス品質に直結していることもあるため、それをすぐにリプレースしたり、AB テストの効果検証に使用することに現場は難色を示します。並行に運用することで既存業務と同等、もしくはそれ以上の結果を得られることの確認が可能であり、実ビジネスの安定運用も担保しながら、実際にAIを活用して業務の意思決定を行った場合のビジネスインパクトや改善点を洗い出しやすくなります。

4つめはAI 受益者である既存業務担当者の目的やスキルや業務負荷を考慮し、予測モデルが価値を提供できる最適なインターフェースを設計することです。例えばAI 受益者である業務担当がR&D部門の研究者やマーケティング担当のようにデータを

扱う業務がメインであれば作成した予測モデルを利用して自身の経験や仮説とあわせてある程度探索的にシミュレーションできる画面を用意することが業務支援と納得度の高いAI活用につながると考えられますし、店舗の現場の日々のオペレーションがメインの業務担当では、自動的かつスピーディに予測された発注量や来店客数の数値情報のみを把握できる仕組みを提供することが業務効率化につながります。

②ステークホルダーの巻き込み

作成した機械学習モデルを実業務に適用する際には現場業務担当と同様に、その業務ラインにおける責任者の合意も得る必要があります。プロジェクトの初期フェーズであるテーマ設定の早い段階から現場担当者とおわせてそのマネジメント層へも期待される効果や取り組みの意義をインプットしておく必要があります。実証実験（PoC）には現場担当者だけではなく、現場のマネジメント層にも要所で参加してもらうことが有用です。

同時に、機械学習モデルの業務適用においてはシステムの連携や自動化のための開発を伴うケースがあり、システム部門やIT基盤構築に責任を持つ部門のキーパーソンもプロジェクトの早い段階から巻き込み、想定されるROIと、考えられるシステムのなりリスク、システム改修に必要なコストと実現可能性とスケジュール感について情報のインプット及び検討をしておく必要があります。

機械学習モデルが作成でき、高いビジネスインパクトが期待でき、現場担当者とも実運用に向けての合意がとれている状態まできたのに、IT部門の上層部の決裁者がプロジェクトに関わっていなかったため、実証実験から実業務適用へ進められなかったというケースも起こり得ます。

プロジェクトの初期から業務フローや実運用までを見越したステークホルダーの洗い出しと承認プロセスを明確にしておく必要があります。

③継続的な改善を考慮した運用設計

機械学習モデルは基本的に過去のデータをもとに学習したモデルを用いて未来を予測します。一方で外部環境や市況の変化により、予測のためのインプットデータの性質が変わって来たり、新たなイン

プットデータが必要になってくることによって機械学習モデルの精度が低下したり、予測のアウトプットが陳腐化するケースが考えられます。

例えば法人営業業務で現時点において受注確率の高い営業先を予測するテーマにおいては毎回同じようなターゲティングを行うようになる、お客様からの声を自動分類するモデルでは過去になかった新たな視点の顧客ニーズを検知できない、といったケースです。

そのような事態を避けるためには定期的に新しい学習データで予測モデルを作り直すことや、人による新たな視点を反映したインプットデータを教師データとして取り込んで機械学習モデルをアップデートしていくという継続的な努力が必要になります。近年ではこれらの機械学習運用プロセスに着目したMLOps [11] という取り組みも注目され始めています。

主に現場の実業務担当やマネジメントを巻き込み、意思決定における各キーパーソンをしっかりとおさえたいうでのソフトランディングを実現し、継続的に機械学習モデルの改善を行う取り組みが継続的なAIビジネス適用への鍵となります。

5. AI民主化に必要なもの

ここまでで、AI民主化の具体的なプロセスであるAIのビジネス適用時に直面する壁とおさえるべきポイントについて述べてきました。これらの壁をより効率的に克服し、企業横断的なAIのビジネス適用を推進していくために必要な要素としてここでは以下4つの視点を述べます。

- ①組織（CoE）の視点
- ②教育と人材の視点
- ③AIソリューションの視点
- ④統合的な変革マネジメントの視点

①組織（CoE）の視点

これまで述べてきたAIのビジネス適用におけるポイントを振り返ると、データサイエンスの高度な知見を有してAIのビジネス適用を推進する組織であるCoE [12] と既存のビジネス知見に強みを持ち業務を実行するLoBの両方の組織が連携しなが

らプロジェクトを進めることが理想的であることがわかります。

テーマ設定フェーズで述べたような全社的なビジネスインパクトを継続的に生み出すには1つのLoBからの機械学習テーマではならず、複数の部門から有望なテーマを複数選出し、CoEの俯瞰的な視点でインパクトの大きいものから優先順位をつけて並走して実行しながら全社的なROIを積み上げていくことが有用です。

データ調達フェーズで述べたような、関連各所のデータホルダーと連携してデータコンディションの調査やデータ調達を実行する調整は、個別の部門がそれぞれに行うのではなくCoEが推進することで効率的に推進できます。

AIモデル開発フェーズで述べたような特微量エンジニアリングやリーケージへの対策にはCoEに属する高度なデータサイエンスの専門家、LoBに属するビジネス現場で培われたドメイン知識を有する経験者の共同作業が必須になります。

業務適用フェーズで述べたような関連各所のキーパーソンを含めたステークホルダーマネジメントはCoEがとりまとめ、推進することで実現可能になります。

同様に、俯瞰的な視点でAIによるビジネスインパクト創出を語るうえでは上層部（エグゼクティブ）からのトップダウンのアプローチと同時に、LoBからの実務課題起案のボトムアップアプローチによる双方向の連携が必要です。CoEはその上層部（エグゼクティブ）とLoBとの連携をつなぐハブとなる機能を果たすことが求められます。CoEとLoBの両方がそれぞれの役割を補い合うことでAIのビジネス適用をスムーズに進めます。

現状、CoEの成り立ちは既存のR&D部門などAIの高い技術力を持った部門がその役割を担うケース、IT部門がその役割を担うケース、LoBからメンバーを選出して構成するケース、などさまざまです。

R&D部門やIT部門で活躍してきた技術に強いメンバーばかりではLoBのビジネスインパクトやROIの視点が不足しますし、逆にLoBで活躍してきた業務知見や社内調整力に強いメンバーばかりではAIモデルの実装力が不足します。これまで述べてきたようにAIのビジネス適用では技術とビジネス

の両方の視点が必要です。それぞれの強みを持ち合わせた人材をバランスよくミックスするか、不足する部分を外部から補うという形でCoE組織を構成することが理想です。

また、CoE組織の志としては、受け身で分析する、データを抽出する、カバランスを重視する、という守りの姿勢ではなく、プロフィットセンターとして積極的にビジネスインパクトを生み出すユースケースをLoBとともに発掘し、実行を推進していくという攻めの姿勢が必要になります。

②教育と人材の視点

特にテーマ設定フェーズにおいてビジネスインパクトを算出したり、ビジネス課題を機械学習の問題に定式化したり、AI開発フェーズでAutoMLツールの活用や特微量エンジニアリングを行う際にはある程度の教育やスキル習得が必要になります。そのような継続的な教育支援をプランニングすることもCoEの重要な役割です。

教育メニューは担当者のレベルと対象に応じて設定する必要があります。既存の研修を受講するという単発のケースもありますが、特にLoBの担当者に対してはAIの業務適用はビジネス価値の創出と密接であるという点をうまく利用して、あくまで担当者自身の業務テーマを改善させるという強いモチベーションを喚起し、「AIスキル習得」という押しつけの文脈ではなく、「自分自身の業務をさらにレベルアップさせるためのOJT」という継続的な立付けで実行することも有用です。それによりAIによる成果を自分自身の業務成果へとダイレクトに転換することができ、当事者意識をもってモチベーションを維持することが可能になります。LoBメンバーに「我が事」として参加してもらえる仕組み、教育が成功の鍵になります。

③AIソリューションの視点

モデリングフェーズにおける予測モデルの自動生成や複数モデルのアンサンブル、ハイパーパラメーターチューニング、業務適用フェーズにおける予測モデルのデプロイ（API化）など、データサイエンティストのノウハウとCPUパワーによって自動化可能な、よりテクニカルな領域はAutoMLなどのソリューションによる解決が効果的です。それらの

フェーズ	変革マネジメントに必要なCoEの役割
テーマ設定	<ul style="list-style-type: none"> ・CoE体制構築、スポンサー巻き込み ・ビジョンとビジネスゴール設定、KPIへの落とし込み ・LoBを巻き込んだビジネスプロセス分析と積極的なテーマ創出 ・ビジネス課題を機械学習問題へ定式化し期待ビジネスインパクトを描く
データ準備	<ul style="list-style-type: none"> ・関連部門を巻き込んだ調整やLoBのドメイン知識組込み ・実証実験を元にした期待ビジネスインパクト/ROIの可視化 ・実証実験の成果をマネジメントやエグゼクティブへインプットする調整力
AI開発	<ul style="list-style-type: none"> ・成果をもとにしたさらなる内外からの必要リソースの調達
業務適用	<ul style="list-style-type: none"> ・プロジェクト実行管理 ・目標/KPI/ROI測定管理 ・LoBと連携したAI実行テーマステータス管理 ・LoBと連携した新たなビジネスプロセスの創出と合意 ・成功事例の社内（エグゼクティブ/スポンサー）啓蒙や教育展開

図2 各フェーズにおける変革マネジメントに必要なCoEの役割

ソリューションによって効率化したコストを、より人間の思考力と調整力が必要とされる入口の課題設定と出口の業務適用へと注力させることが必要です。

AIのビジネス活用を成功させる、付加価値を生み出すためにはテーマ設定やビジネス価値の創出、関連各所との交渉、現場の新たなビジネスプロセスの創造など、より上流工程の業務の重要性が高まっています。それはつまり、本来はLoB側にいた人材がよりAIを活用しやすい仕組みを整えていくことの必要性を意味します。

AutoMLなどのAIソリューションを活用してLoB人材のAI活用ハードルを下げるが必要である一方で、あくまでもAIソリューションは手段のひとつであることを忘れてはならず、AIを適用するビジネスの目的や組織の成熟度にあわせて選定する必要があります。

④統合的な変革マネジメントの視点

AIのビジネス適用はこれまで述べてきた難しさを有した複数のフェーズを、CoEとLoBと関連する各部門が連携しながら乗り越えていくひとつのプロジェクトマネジメントの側面を持つと同時に、AIのビジネス適用という点から、既存のビジネスプロセスの変革という側面も持ち合わせています。

そのため、PMBOK [13] にて提唱されるような従来のプロジェクトマネジメントのフレームワークに加えて、変革マネジメント [14] で提唱されるような、変化やリスクを恐れることなく、チームを構築し、ビジョンを描き、さらなる仲間を巻き込み、短期的に小さな成功を積み重ねて大きな変革へと結びつけるという強いリーダーシップが必要とされる

取り組みでもあります。

具体的には、図2に示すように、ビジネスゴールの設定と、そこからブレイクダウンされる各実行テーマの目指すビジネスインパクトの可視化、及びマイルストンの設定とスケジューリング、実行体制の構築とステークホルダーの巻き込み、進捗やROI管理、最終的な成果の社内展開など、横断的かつ統合的なプロジェクト管理が必要となります。

6. おわりに

AIはDeep Learningに代表されるようにその要素技術やエポックメイキングなユースケースがクローズアップされることが多いですが、確実なビジネスインパクトへとつなげるAI活用や本稿で述べたAI民主化を実現させるためには、モデリング手法などのAI要素技術のみならず、入口のテーマ設定から出口の業務適用までの一連の実行プロセス上で発生しうる各種課題に対する地道な解決努力と、組織/教育/プラットフォームの各視点を統合的に織り込んだ変革マネジメントが必要になります。

今後も弊社はAI民主化の実現を成功させるお客様のビジネスパートナーとして、AI活用によるビジネス価値創出をご支援し続けて参ります。

注

DataRobotはDataRobot, Inc.の登録商標です。

GoogleはGoogle Inc.の登録商標です。

その他本文記載の会社名及び製品名は、それぞれ各社の商標又は登録商標です。

参考文献

- [1] McKinsey & Company 「McKinsey Global Survey 2018 “AI adoption advances, but foundational barriers remain”」(2018/11) <https://www.mckinsey.com/featured-insights/artificial-intelligence/ai-adoption-advances-but-foundational-barriers-remain>
- [2] 国立研究開発法人新エネルギー・産業技術総合開発機構 (NEDO) 「産業分野における人工知能及びその内の機械学習の活用状況及び人工知能技術の安全性に関する調査」(2019/07) より.
- [3] 松尾豊著「人工知能は人間を超えるか」(KADOKAWA/中経出版 2015/03) による定義より引用. 例えばビジネステーマにおける需要予測や不良品の検知など, ある特定の業務に特化して応用できるAIのことを指します.
- [4] 厳密には5つめのフェーズとして運用フェーズがありますが, ここでは割愛しています.
- [5] 予測モデル学習時のクロスバリデーションにおいて, 学習データへの過学習やリークを防ぐために行う適切なパーティショニングを検討すること, もしくはその方法論のことをここではバリデーションスキームと呼んでいます.
- [6] 実際には本稿で述べるもの以外にも, ケースによってさまざまな壁が存在しますが, 代表的なもののみを取り上げます.
- [7] 実際の業務ではそこまで十分なデータが得られないケースも多く, その場合はダウンサンプリングやデータにウェイトをかけるなどの対応を行います.
- [8] Auto Machine Learning の略. 主に機械学習モデルの構築や選択, デプロイまでの作業効率化, 自動化を実現する仕組みやサービスの総称.
- [9] 代表的な例として, ミスナル (Missenard, 1937), グレゴルチュク (Gregorczyk, 1972) などが考案した体感温度の算出式があります.
- [10] 通常, 機械学習ではインプットデータを学習用データと検証用データにスプリットし, 学習用データで学習し, 検証データで検証するというこ

とを繰り返してハイパーパラメーターのチューニングやモデル構築を行います (クロスバリデーション).

- [11] Machine Learning Operations の略. AI/機械学習を実業務に適用し, かつ自動で, 精度を保ちながら, 適切なガバナンスのもとに継続的に運用するための仕組みや取組みの総称.
- [12] Center Of Excellence の略. もともとは教育機関などにおいて優秀な人材や設備を集約した拠点を示す言葉. ビジネスの世界でも人材やノウハウを集約した実行組織という意味で使われる. 対応する概念として, 実業務を実行するフロントライン部門を表す言葉として LoB (Line of Business の略) があり, 対比して用いられる.
- [13] Project Management Body of Knowledge の略. PMI (米国プロジェクトマネジメント協会) が定義したプロジェクトマネジメントの世界標準. 5つのプロセスと 10 の知識エリアで構成される.
- [14] 組織変革を推進・加速させ, 経営を成功に導くマネジメント手法. 【参考文献】ジョン・P・コッター『Leading Change』日経 BP 社 (2002/04)

略歴

多胡 篤 (たご あつし)

ソリューション企画コンサルティングセンター AIソリューショングループ コンサルティングチームリーダー.

教育系事業会社にてデータ分析業務に従事した後, 新日鉄住金ソリューションズ株式会社入社. データサイエンス領域の新規ソリューション企画, パートナー企業とのビジネス構築などを経て現在は DataRobot 導入コンサルティングに従事.

向 正道 (むかい まさみち)

人事本部 人材開発部 専門部長.

1991年新日本製鐵株式会社入社. 2001年新日鉄ソリューションズ株式会社転籍. コンサルティング, 事業企画, 人材開発等の業務に従事.