

生成 AI の活用を含む AI サービスシステムの 業務適用可能性分析

－ 保険会社の業務を中心とした事例分析を踏まえて －

竹内広宜(武蔵大学 経済学部)

目次

あらまし	2
1 章 はじめに	2
2 章 関連研究	5
3 章 研究対象と研究課題	6
3.1 エンタープライズアーキテクチャと AI サービスシステム	6
3.2 エンタープライズ領域における AI サービスシステム	8
3.3 大規模言語モデルと生成 AI	10
3.4 知識流通モデル	10
3.5 研究課題	12
4 章 提案手法	13
4.1 AI 技術の業務適用可能性評価	13
4.2 生成 AI の適用可能性分析	18
5 章 事例分析による評価	22
5.1 AI サービスシステムの適用可能性分析手法の評価	22
5.2 生成 AI の適用可能性分析手法の評価	23
6 章 考察	24
7 章 まとめ	26
参考文献	26

あらまし

企業内では、様々な業務に機械学習を中心とした AI 技術を適用する試みが進められている。また、生成 AI についても数多くの試行を通してその適用可能性が評価されている。しかしながら、検証プロジェクトを実施したものの、全く効果が得られない場合も多く存在する。本研究は既存業務に機械学習や生成 AI を適用する状況を対象とする。そして、業務への機械学習および生成 AI の適用可能性を事前に判断するための業務分析手法を考え、対象の業務タスクや構築するサービスシステムが満たすべき条件を導出する。そして、保険業界の実業務を対象にした事例分析を通して、提案手法が機械学習および生成 AI を業務適用する際の必要条件となっていることを確認する。

1 章 はじめに

深層学習をはじめとした機械学習技術の発展にともない、人工知能 (Artificial Intelligence: AI) 技術の社会実装が始まっている。機械学習や自然言語処理といった AI の要素技術 (AI 技術) が一部 Application Programming Interface (API) として公開されている。それに伴い、アプリケーション開発者は適用対象に関するデータを準備することで AI 技術の業務適用を検討することが可能となりつつある。保険機関が含まれる金融・保険業界においても AI 技術の適用が開始されており、営業事務支援、コールセンター (ヘルプデスク) のオペレーションといった領域は AI 技術と親和性が高く、2028 年業務代替性が約 40% になると推測されていた [1]。このような背景から、2010 年代後半から AI 技術の導入を評価する検証 (Proof of Concept: POC) プロジェクトが多数実施されてきた。

AI 技術のオフィス業務適用にあたって、経営者をはじめとした利用者側には、AI に対する過度な期待がある一方、AI 技術は業務の一部タスクにのみ適用可能であることが多い現実がある。また、システムの構築にあたって対象業務に関するデータを元に訓練データを作成する必要がある、そのためには、業務に関連する知識や経験が必要となる。例えば、事務手続きについての質問に回答する照会応答業務において、AI 技術を用いて質問を自動分類し、回答候補を照会応答担当者に提示することを考える。この場合、業務マニュアル中の各記述について、どのような質問に対する回答かという情報を付与し、訓練データとして作成することが考えられる。このような作業は、ベンダーを含む開発部門側だけではできないため、開発を依頼する事業部門のメンバーがプロジェクトに参画する必要がある。また、AI 技術の中で重要となっている機械学習は、確率的な振る舞いをし、入力によって異なる出力が確率を元にした確信度とともに得られる。そのため、入力によっては望ましい結果が得られない場合がある。適用業務によっては、例

例えば確信度の低い出力が得られた場合は複数の候補を出力するといった後処理を別途開発し、システムとしてその利用者が満足する結果を提示することも必要となる。その結果、事業部門側がシステム構築にかかるコストに見合う効果が得られる見込みを立てられず、業務適用の検証段階でプロジェクトが終わり、AI 技術の検証に多くのコストをかけたにも関わらず本格展開に至らない状況も生じている [2]。

このように AI サービスシステムの開発では、従来のシステム開発以上に開発者以外のプロジェクト関係者が要求からテスト、サービスイン後の運用までに関わる必要があるなどこれまでのソフトウェア開発とは異なる点が多く、様々な課題が示されている [3] [4]。このような状況に対して、AI 技術の中核となる機械学習を活用したシステムの特徴やそのようなシステムの開発における工学的課題と解決策考案の必要性が機械学習工学として提唱され [5]、その体系化が進んでいる [6]。この機械学習工学の成果により、統計的機械学習や深層学習を用いたアプリケーションの開発は大きく進みつつあり、機械学習モデルを利用したシステムを開発するためのプラットフォームも容易に利用可能になっており、保険機関でも AI サービスシステムの開発プロジェクトが進められている。

ここで、AI サービスシステムの開発にあたっては、その検討段階において事業部門（保険業務を実施する部門）とシステム開発部門が開発対象について共通理解を持つことが重要である。これに対して、対象業務で目指すゴール、利用するアプリケーション、必要となるデータなどとの関係をビジネス IT アライメントとして表す研究 [7] や、開発する上で必要な活動とその担い手、その活動によって満たされる開発対象の品質との関係を示した開発モデル [8]の研究が行われている。これらでは、ビジネス課題への技術的解決策の検討にデータサイエンティスト が加わり、業務への AI 技術の適用可能性の評価を行うことを想定している。この時、構想段階でデータサイエンティスト のプロジェクトへの参画が期待できないことが多い。すると、業務への AI 技術の適用可能性が十分に検討されないまま、プロジェクトが進み、結果として業務に効果的に活用できない AI サービスシステムが開発される可能性が高くなる。

一方、対象分野のデータを訓練データとして用意し訓練モデルを作成することとは別のアプローチとして、近年、深層学習を用いた大規模な訓練済みモデルが公開され様々な用途に用いることが進められている。中でも、大量の文書データで深層学習モデルを訓練した大規模言語モデル (Large Language Model: LLM) が注目を浴びている。LLM は、ファインチューニングと呼ばれる特定のタスクに特化した訓練を追加することで、テキスト分類・生成や感情分析、文章要約といったさまざまな自然言語処理タスクに適用できるという特徴がある。中でも対話応答に特化したファインチューニングより実現された ChatGPT をはじめとした対話アプリケーションは大きく注目されている。これらの

アプリケーションは利用者の入力に応じた出力を自動的に生成することから生成 AI と呼ばれる。生成 AI には言語以外にも画像生成など様々なアプリケーションがあるが、本研究では ChatGPT や Google Bard といった LLM を用いたアプリケーションを生成 AI と呼び、研究の対象とする。

生成 AI の結果はあたかも人間(専門家)が書いたもののような自然な形式となっている。そのため文書の校正・要約・翻訳といった作業、プログラミング作業、アイデア出しの支援、学習のサポートなどの場面での活用が期待される。一方、生成 AI の出力は 100%正確というわけではなく場合によってはあり得ない間違いを出力することがある。ありえない事実を生成 AI が出力をする現象は幻覚(hallucination)と呼ばれるが、この時、生成 AI は間違った結果であってもごく自然な形式で出力するため、利用者はその出力が本当のことか、幻覚かを区別することが難しい。このような性質があるため、生成 AI の利用を制限すべき適用領域も存在する。そのような中、生成 AI の業務適用に関して様々なガイドラインが提示されている。また、幻覚を起こさないよう、生成 AI への入力(プロンプト)を工夫する試みも広く行われている。しかしながら、生成 AI を業務のどのような部分に適用できるのか、といった点については適用分野ごとに試行が先行している状況である。保険業務を考えると、その商品の性質上、生成 AI による幻覚は大きな問題となる。したがって、試行に多大なコストと時間をかけた後に、生成 AI を使ったサービスの提供はリスクが大きいと、難しいという結果となる可能性も十分にある。

そこで本研究では、機械学習や生成 AI を利用したサービスを業務の中で実現するにあたって、これらの適用可否を評価する手法を検討する。具体的には、機械学習の適用可能性については人間の認知活動、生成 AI の活用については知識獲得に注目し、業務を構成する活動における活動をモデルとして表現する。そして機械学習の適用可能性については、そのモデルからサービスシステムが満たすべき条件を抽出し、生成 AI の活用では、業務の最上位の目標を GQM+Strategies と呼ばれる分析法 [9]におけるゴールストラテジー分解によって得られたストラテジーに対して知識流通モデルを参照しながら、生成 AI の適用に必要な条件を満たすかどうかを評価する。この提案手法を保険機関の業務を対象として適用し、その有効性を確認する。

本研究では保険機関でのプロジェクトを分析するが、そこで得られる結果は保険機関における業務に大きく依存するものではないと考えられる。しかしながら、保険機関ではオフィス業務などに AI 技術を適用するための検証プロジェクトが多数実施されており、生成 AI の適用を検討する領域は広い。本研究での成果が効果的に活用できる業界だと考えられる。

本論文の構成は以下の通りである。2 章で関連研究を述べた後、3 章で研究対象や課題を概観し、研究仮説を述べる。そして 4 章で解決手

法について説明し、5章で分析例について述べる。6章で今後の方向性について考察した後、最後に7章で本研究のまとめを行う。

2章 関連研究

本研究では機械学習といったAIの要素技術を使ったシステムの開発プロジェクトを対象とする。AIのシステムの開発については、例えばIEEEの調査[10]で社会実装が安定的に進んでいる領域が抽出されている。そのようなプロジェクトに関する研究として、[11]ではプロトタイピングを活用し、関係者で要求の抽出と検証を繰り返し行いながら開発を進める手法が議論されている。また、ビッグデータ解析やAI技術の活用においてデータサイエンティストが担う役割や分析プロセスについても議論されている[12][13]。機械学習を用いたシステムの開発における汎用的なプロセスは[14]で提案されている。一方、対象業務領域における機械学習の適用性評価は、モデルの選定プロセスにおける活動として位置づけられているものの、実践的な評価方法については議論されていない。

一方、ChatGPTやGoogle Bardに代表される大規模言語モデルを用いた生成AIは、文書の校正・要約・翻訳などの作業や、調査などの知識を必要とする作業の支援に利用されている[15]。このような観点から、専門的なスキルを必要とする作業の一つであるソフトウェア開発における活用が期待されておりプログラミングへの利用が評価されている[16]。また、要求分析・設計におけるモデリングの活用が議論されている[17][18]。しかしながら、生成AIについても特定の領域においてその可能性が議論されているが、適用可能な領域を同定する手法は検討されていない。

ここで、ITの業務適用を分析する手法として、ビジネスゴール、ビジネスプロセス、アプリケーションなどの間の関係をモデル化することが考えられている。モデル化のアプローチとしてエンタープライズアーキテクチャ(EA)があり、ITシステムを経営および開発視点で議論すること(ビジネスITアライメント)などで用いられている[19]。EAはITシステムそのものを表現するだけでなく、ITシステムの開発や運用を表現することも可能である。ITシステムの運用については[20]で、ITシステムのリスク管理については[21]でEAを用いたモデル化が行われている。AIサービスシステムの開発プロセスにおいても対象とするビジネス課題に対してどのようなAIソリューションが考えられるか、また、どのAIエンジンが適用できるかといったことを検討する企画・構想フェーズがある[14]。また、その活動にデータサイエンティストが参画することが想定した開発モデルも提案されてい

る [8]。しかし、企画・構想の初期段階からデータサイエンティストが参画することは少なく、その場合は、技術の適用可能性を他のプロジェクト担当者が行うことになる。一方、対象のビジネス課題に対して生成 AI を含めた AI 技術が適応可能かをデータサイエンティストが判断する過程を明確化し、方法論としてまとめた試みはほとんどない。

3 章 研究対象と研究課題

3.1 エンタープライズアーキテクチャと AI サービスシステム

本研究では、ビジネスアプリケーションシステムとして AI サービスシステムを対象とし、企業などにおいてその開発プロジェクトについて考える。ここではまずプロジェクト管理の視点で、AI サービスシステムについてモデルとして表現する。企業などの組織内で開発されるサービスシステムは何らかの業務で用いられる。したがって、①どのようなビジネス目標を達成するために、②どのようなビジネスプロセスで、③どのようなアプリケーションを使うのか、ということが記述される必要がある。そのようなビジネスと IT アプリケーションの両方視点で業務システムを表現する手法としてエンタープライズアーキテクチャ (Enterprise Architecture: EA) と呼ばれるモデリング手法がある。EA の代表的なモデリング言語である ArchiMate [23] を用いると、一般的なビジネスアプリケーションは図 1 のように表される。




図 1 ArchiMate で表現した一般的なビジネスアプリケーション




ArchiMate では主に、ビジネス層、アプリケーション層、動機拡張に分

けて対象を記述する。ここで代表的な要素や関係は表 1、2 のように定義されている。

表 1 ArchiMate で定義されている代表的なモデル構成要素

ビジネス層の要素		アプリケーション層の要素		動機拡張の要素	
	ビジネスアクター		アプリケーションサービス		ドライバ
	ビジネスサービス		アプリケーション機能		ゴール
	ビジネスプロセス		アプリケーションコンポーネント		アセスメント
	ビジネスオブジェクト		データオブジェクト		

表 2 ArchiMate で定義されているモデルの構成要素間の関係

表記	関係名	意味
	Association	一般的な関係
	Realization	目的が手段により実現される関係
	Composition	上位が下位に分解される関係
	Influence	肯定または否定の影響の関係
	Access	データオブジェクトを操作する関係
	Assignment	割り当てられた実行する主体やアプリケーションコンポーネンを示す関係

本研究ではオフィス業務へ AI 技術を適用するプロジェクトを対象とする。オフィス業務において人間は様々な知的活動を行っている。人間の知能には分析知能・創造知能・実践知能 があると考えられている [24]が、ここでは分析知能を用いたオフィス業務活動を AI 技術によって支援することを考える。分析知能とは、与えられた入力に対して、複数ある選択肢の中から最適なものを選択する知能である。事務処理に関する問い合わせへの回答や、書類の審査などの活動では、この分析知能が用いられていると考えられる。分析知能の実現として機械学習の活用が考えられる。対象業務に基づき業務文書から選択肢（問い合わせ業務における回答や審査業務における審査結果）を定義し、事前に用意した入力例に正解となる選択肢を付与することで訓練データを作ることができる。それを機械学習で訓練することで、様々な入力に対して選択肢を自動的に選び、出力することができる。本研究では、機械学習などの AI エンジンを用いて、オフィス業務活動を支援するシステムを対象とする。このようなシステムが AI サービスシステムとして定義される。

AI エンジンとして機械学習を用いた場合、AI サービスシステムは

訓練データ (AI リソース) を機械学習アルゴリズムに投入し訓練済みモデル (AI モデル) を作成する部分 (AI 訓練エンジン) と、訓練済みモデルに対して入力データを投入し 出力を得る部分 (AI ランタイムエンジン) に分かれる。AI サービスシステムを開発する際には、対象業務のデータから訓練データを作り、訓練済みモデルを作るプロセスと、訓練済みモデルを利用する AI エンジンを使った業務アプリケーション (AI アプリケーション) を開発し、利用するプロセスがある。これらの要素を ArchiMate で表現すると、AI サービスシステムは図 2 のようになる。




図 2 ArchiMate で表現した ML サービスシステム

本研究では、以降、この AI サービスシステムを構築することを AI プロジェクトと呼ぶ。

3.2 エンタープライズ領域における AI サービスシステム

機械学習技術は人工知能 (Artificial Intelligence: AI) の重要な要素技術の 1 つであり、AI への期待の高まりと共に社会の様々な分野への適用が開始されている。マッキンゼーの調査 [25] では 19 の産業における 400 以上のユースケースを分析した結果、顧客サービス管理や販促といったマーケティング・営業領域のビジネス課題や、予知保全や歩留まり最適化といったサプライチェーン管理・製造領域のビジネス課題に機械学習技術を適用する潜在的な価値があるを示している。ここでは金融業界における調査 [2] [26] で示されている実践例について 2 つほど述べる。

一つ目の例はコールセンターのオペレーションにおける活用である。多くの企業がコールセンターを開設し、顧客や社内からの問い合わせに回答する照会応答業務を行っている。例えば金融機関のコールセンターのオペレータは、照会応答業務として顧客や社員からの問い合わせに対し、関連する業務文書 (FAQ やマニュアル) を探し出し、それを指差し確認しながら回答を行っている。そして、問い合わせによっては、

関連する業務文書を探し出す時間が長くなっていた。このような状況に対し、質問者（問い合わせをして来た顧客や社員）とオペレータとの会話の声を音声認識によりリアルタイムでテキスト化し、そこから ML 技術を用いた分類によって会話のトピックを推定、その結果を基に関連する業務文書を検索するシステムが開発されている。そのシステムの概要図を図 3 に示す。このシステムの活用により、オペレータは質問者と会話をしながら、画面に出力された回答候補から適切なものを選択し、指差し確認しながら回答を読み上げることで効果的に業務を進められるようになっている。このシステムの導入によって、回答までにかかる時間の短縮だけではなく、オペレータの新人教育にかかる期間を短くすることや、問い合わせ対応の品質向上という効果が得られている。




図 3 コールセンターにおける照会応答支援システム

二つ目に、事務業務への活用として海外送金業務への活用をあげる。銀行では、個人や法人から依頼を受け海外への送金を行っている。この海外送金業務では、顧客が指定する最終的な送金先に応じた仕向先に銀行は送金する。したがって、海外送金業務では、顧客からの依頼書に自然言語で書かれた送金先記述を元に仕向先を担当者が判定し送金する必要がある。この時、送金先記述から送金先の情報である銀行名、都市名そして銀行コードを機械学習技術で自動抽出し、その結果からビジネスルールをもとに仕向先判定を行うシステムが開発されている。このシステムの概要を図 4 に示す。




図 4 海外送金業務支援システムの処理概要

この支援システムにより仕向先判定の作業が担当者の熟練度や送金先

についての記載内容に大きく依存せずに進められるようになっている。

3.3 大規模言語モデルと生成 AI

言語モデル(Language Model)は、ある単語列から次に出現する各単語の出現確率を予測するモデルである。機械学習では通常、説明変数となるデータに対して正解である目的変数を付与した訓練データを用意し、機械学習モデルを訓練する。この訓練データの準備に、正解を付与する人手作業が発生することが機械学習の社会実装における課題となっている。

一方、言語モデルの学習では、既存のテキストに正解を人手で付与する必要がなく、テキストをそのまま訓練データとして利用することができる。このような学習方法を自己教師学習と呼ぶ。自己教師学習によって入力テキストに対して次に来る単語を予測する言語モデルを大規模パラメータで構成される深層学習モデルで構成し、大量のデータで訓練することが行われており [27]、これが大規模言語モデル(LLM)と呼ばれている。LLM は次の単語を高精度で予測するモデルであるため、文を生成することができる。ここで利用者の入力に対して文や画像を生成する仕組みは生成 AI と呼ばれている。

LLM の特徴として、事前訓練済みモデルとして翻訳や文書校正など文を生成する別の目的への活用がある。目的(タスク)に応じた訓練(ファインチューニング)を追加することができ、それぞれのタスクで高精度の性能を示すことが知られている [28]。この中で、対話を想定したファインチューニングによって、あたかも専門家と対話をする生成 AI が実現され [29]、ChatGPT や Bard といったアプリケーションが公開されている。本研究では、LLM を用いた生成 AI のうち対話型アプリケーションを研究対象とし、以降 ChatGPT や Bard のようなアプリケーションを生成 AI アプリケーションや生成 AI と呼ぶ。

3.4 知識流通モデル

企業などの組織では、業務の目標を達成するためにコミュニケーションを通して知識がやりとりされる(知識流通)。ここで知識創造プロセスについて SECI モデルが考えられている [30]。SECI モデルは以下の4つの活動からなる。

- S(共同化)：経験を通して暗黙知を他者に渡す(Socialization)
- E(表出化)：暗黙知から形式知へ変換(Externalization)
- C(連結化)：表出化された形式知を他の知識と組み合わせ、新しい知識を作り出す(Combination)

- I(内面化)：連結化でできた知識を実践を通して暗黙知とする (Internalization)

これをエンタープライズアーキテクチャの代表的なモデリング言語である ArchiMate で表すと図 5 となる。




図 5 : SECI モデル

ある人(X)が持つ暗黙知を形式知として別の人(Y)に伝えることで、その暗黙知が業務に活用されることを考えると SECI モデルは業務における知識流通モデルを表す際の基盤の一つとなる。

この SECI モデルに加えて仲介知モデル(PSFCR モデル) [31]も知識流通を表すモデルとして使われている。仲介知とは構成員が組織内のデジタルメディアで組織横断的に発言する断片的で客観的あるいは主観的な経験知識 [31]のことで、仲介知モデルは SECI モデルに以下の 4 つの知識変換を追加したモデルとして提案されている。

- P(公開化)：暗黙知から仲介知への変換(Publication)
- S(洗練化)：仲介知から形式知への変換(Sophistication)
- F(断片化)：形式知から仲介知への変換(Fragmentation)
- C(協働化)：仲介知を共有すること(Collaboration)
- R(共鳴化)：仲介知から暗黙知への変換(Resonant Formation)

この仲介知モデルを SECI モデルと同様に ArchiMate で表すと図 6 として表される。




図 6：仲介知モデル

3.5 研究課題

AI サービスシステムの企画・検討段階において、事業部門の企画担当者は IT 部門 (IT ベンダー) のビジネスアナリストやデータサイエンティストらとともに対象業務や適用する AI コンポーネント (アルゴリズム) を検討する。様々な業種の様々な業務において、AI サービスシステムを実現することは、AI 技術の社会適用を進めていく上で重要となっている。しかしながら、どの業務のどの作業に機械学習技術を始めた AI 技術が適用できるのかといった判断はプロジェクトを企画するビジネス部門の企画担当者および IT 部門の経験やスキルに依存している。また、AI 技術を適用できる場合に、AI サービスシステムとして実現するに必要な前提条件を満たしているかどうかを検証は、個々のプロジェクト立案で異なる。その結果、プロジェクト遂行時に「課題設定が間違っている」「適切なデータが十分でない」といった課題が発生し、プロジェクトの成功を妨げる要因となっている。

一方、新たに生成 AI 登場し、その出力される文書は品質がよく、またその内容の精度も高いことが広く知られるようになった。生成 AI の振舞いはあたかも人間の専門家のものに感じられるため、その活用は大きな可能性があると考えられている。しかし一方で、出力される文書の中には幻覚と呼ばれる間違いが含まれることも少なくない。生成 AI の出力は一見すると専門家が自信を持って回答しているように見えるため、出力される文書の内容が正しいかどうかを、利用者が判別することが難しい場合もある。また、生成 AI を使ったアプリケーションの中には利用者と対話するものもある。そのため利用者からの入力収集されることから入力データを慎重に扱わなければならない利用領域も存在する。このような状況において、企業等の業務で利用するた

めのガイドラインが公表されている¹。このようなガイドラインには、生成 AI を組み込んだサービスを利用・開発する際のルールや留意点が記載されている。しかしながらガイドラインに書かれているルールや留意的だけでは、組織内にさまざまな活動がある中、どの場面で生成 AI を効果的に利用できるかを特定することは難しい。一方、生成 AI を効果的に活用するために、プロンプトと呼ばれる利用者からの問い合わせを工夫する試みも行われている。しかし、試行錯誤が先行しており、利用効果が少ない領域でプロンプトの検証を行うことも少くない。

そこで、本研究では以下を取り組むべき研究課題 (RQ) とする。

RQ1: AI サービスシステムの実現可能性を評価することはできるか？

RQ2: 生成 AI を効果的に適用できる業務タスクを特定できるか？

これらの研究課題について、本研究では業務分析手法を提案し、保険業界ははじめとした事例を通して検証する。

RQ1 については AI サービスシステムの実現可能性を評価するための業務分析手法を検討する。既存のオフィス業務内の作業に機械学習を適用することを想定し、業務モデリングを通して、その業務作業が満たすべき特徴を導出する。また、AI サービスシステムとして実現にあたっての前提条件も導出する。それらを AI 技術の適用可能性を評価する指標（前提条件）として提案する。RQ2 に対しては生成 AI の適用可否を評価する業務分析手法を検討する。具体的には、知識を獲得するために生成系 AI を利用することから、業務における活動を、エンタープライズアーキテクチャを用いて知識流通モデルとして表す。そして、そのモデル表現をもとに、業務活動を行う上で生成系 AI を利用する際に求められる特性を抽出し、生成系 AI の適用可能性を判定する手法を構築する。

4 章 提案手法

4.1 AI 技術の業務適用可能性評価

本研究で対象とする企業などの組織で実施される業務は様々な業務

¹ ディープラーニング協会によるガイドライン
<https://www.jdla.org/document/ai-guideline>

作業(タスク)に分解されるとする。そして、業務に携わる担当者は決められた業務タスク(複数の場合もありうる)を実施するとする。例えば図 4 に示した海外送金業務では、仕向先判定作業が業務タスクの 1 つとなり、専門の担当者が実施している。このような業務タスクを AI サービスシステムで支援することを考える。

人間の認知活動のモデルの一つに OODA ループ(ODDA モデル)がある[32]。このモデルでは、人間の認知活動は、外界からの入力(Fact)を観測(Observation)し、認知した結果(Perception)を整理(Orientation)する。そして、得られた仮説(Hypotheses)に対して、判断(Decision)を行い、その意思決定結果(Directives)をもとに行動(Action)することで、出力(Outcomes)を外界に提供すると考えられている。これらの各活動では、その結果によっては以前の活動に戻る(ループ)することも想定されている。

このモデルを用いて業務タスクを EA で表現することを考える。OODA モデルにおける各活動はビジネスプロセスとして表される。また、各活動の入出力はビジネスオブジェクトとして表すことができる。業務タスクにおける各ビジネスプロセスおよびビジネスオブジェクトの定義および仕向先判定作業における例を表 3 に示す。

表 3: OODA モデルの構成要素と関連するビジネスオブジェクト

Process	説明	例: 仕向先判定作業	Business Object	説明	例: 仕向先判定作業
Observation	入力データから利用する箇所を抽出し必要な形式に変換する	送金依頼書から、送金先記述の部分を抜き出す	Facts	様々な形式の業務タスクの入力データ	送金依頼書
Orientation	入力データを対象業務の目的に沿って、構造化する	自然言語記述から送金先情報を抜き出す	Perceptions	必要な部分を取り出し、処理可能な形に変換したデータ	送金先記述(自然言語記述)
Decision	構造化情報に適合する選択肢を得る	送金先情報を仕向先判定ルールに適用する	Hypotheses	業務の目的に沿って構造化された入力データ	送金先情報
Action	選択肢の中から、制約を満たすものを選ぶ	マッチしたルールの最終端に書かれている内容を仕向先として判定する	Directives	タスクとして実行する選択肢の候補	仕向先判定ルールにマッチした部分
			Outcomes	業務タスクとして実行する選択肢、次の業務タスクの入力	仕向先

また、OODA モデルを、ArchiMate を用いて表現すると図 7 となる。既存のオフィス業務において AI 技術を効果的に適用するためには、図 7 のモデルより業務タスクが次の特徴を持つと仮定する。




図 7: OODA モデルで表した業務タスク

- **MC1:** 業務タスクが OODA モデルとして表現でき、途中で前ステップに戻るフィードバックループは基本存在しない
- **MC2:** 外界からの業務タスクへの入力 (Facts) の形式は固定である
- **MC3:** OODA モデルのうち OOD のステップが占める時間が長い

MC1 は、業務タスクを行う際に十分な成果 (Outcomes) が得られない場合、再度入力を得る。または、担当者 (Practitioner) は上席担当者に確認や相談を行い、タスクを実施するという特徴である。C2 は、業務タスクには複数種類の入力形式がある場合でも、その数は固定という特徴である。ここで、業務タスクへの入力形式とは入力フォーマットやデータ形式 (音声、テキスト) であり、その形式が固定であるということを示す。C3 は、業務タスクにおいて Orientation および Decision のステップが占める割合が長く、担当者の作業経験に依存するという特徴を示している。

ここで、ビジネスプロセスとして表現された業務タスクを AI アプリケーションサービスで (半) 自動化することを考える。OODA モデルで表される業務タスクで AI アプリケーションサービスを用いる状況を EA で表現すると図 7 となる。




図 7 : OODA プロセス内で利用される AI サービスシステム

担当者は AI アプリケーションコンポーネントが出力する成果物 (Outcomes) を参照し、業務タスクを実施するが、必要に応じて中間生成物 (Perceptions, Hypotheses, Directives) を参照する。図 7 で表されたモデルから、業務タスク内で AI アプリケーションサービスを効果的に用いるためには以下の条件を満たす必要があると仮定する。

- **MC4:**担当者は、不確かな Outcomes が得られたと判断した際、中間生成物を参照することで、適切な対応が取れる
- **MC5:**担当者は、場合によっては Outcomes や中間生成物を参照せずに入力から業務タスクを実施することも可能である

AI アプリケーションサービスで業務タスクを(半)自動化する状況は必ずしも担当者の介在がなくなることは想定されず、成果物に対する確認作業の後、次の業務タスクに成果物が渡され则认为。そのため、MC4 と MC5 については、アプリケーションコンポーネントから得られた成果物に満足しない場合に担当者が自身で中間成果物を確認し成果物を生成することや、場合によっては入力から自身で成果物を作成することが可能であるという条件を示している。

次に、AI アプリケーションサービスを実現する AI アプリケーションコンポーネントについて考える。オフィス業務を構成するタスクは、知識集約型タスクと捉えることができる。知識集約型データ処理システム (Knowledge Intensive Data-processing System: KIDS) を表すモデルが [33] で提案されている。このモデルは、入力データから業務タスクに必要な部分を抽出するコンポーネント (Transformation)、対象業務の目的に沿ってデータを構造化するコンポーネント (Assessment)、構造化された情報に適合する出力候補 (選択肢) を得るコンポーネント (Resolution)、出力候補の中から決められた制約を満たすものを選ぶコンポーネント (Enactment) で構成される。ここで各コンポーネントの入出力が ODDA モデルにおけるビジネスオブジェクト (入力, 中間成果物, 成果物) に相当することがわかる。また、それぞれのコンポーネントでは処理の段階で、事前に作成した何らかのモデルをデータオブジェクトとして参照する。これらの関係を EA で表現すると図 8 となる。




図 8 : AI サービスを構成するアプリケーションコンポーネントとデータオブジェクト

また、各コンポーネントやデータオブジェクトの具体例を表 4 に示す。

表 4：AI アプリケーションコンポーネントの構成要素と関連するデータオブジェクト

Component	説明	例: 仕向先判定作業	Data Object	説明	例: 仕向先判定作業
Transformation	入力データから利用する箇所を抽出し必要な形式に変換する	送金依頼書から、送金先記述の部分を抜き出す	Transformation Model	入力データから必要な部分を後段の処理で使いやすい形式に変換するためのモデル	送金依頼書から送金先記述を抜き出すロジック
Assessment	入力データを対象業務の目的に沿って、構造化する	自然言語記述から送金先情報(銀行名、コード、都市名、国名)を抜き出す	Assessment Model	対象分野で必要な構造化情報を抽出するためのモデル	送金先情報(銀行名、コード、都市名、国名)を固有表現抽出するための学習モデル
Resolution	構造化情報に適合する選択肢を得る	送金先情報と金額を仕向先判定ルールに適用し、マッチする部分を得る	Resolution Model	大量の選択肢の中から該当する候補を得るためのモデル	仕向先を決定するためのビジネスルール
Enactment	選択肢の中から、決められた制約を満たすものを選ぶ	マッチしたルールがあり、その最終端末が仕向先である場合、出力する	Enactment Model	候補の中から出力を決定するためのモデル	マッチしたルールの最終端末の評価式

OODA モデルで表せる業務タスクを、機械学習を中心として AI 技術を含んだ図 8 のような知識集約型データ処理システムで実現する際、以下の条件を満たす必要があると仮定する。

- **MC6:** 汎用のモデルで Transformation が実現される(精度を改善するためにモデルをアップデートすることができる)
- **MC7:** 対象の業務タスクに必要な構造化情報(Hypotheses)を定義でき、その抽出を実現するための Assessment モデル(辞書ルールやロジック、訓練済みパラメータ)を作成するための業務データが十分に存在する
- **MC8:** 対象となる業務タスクにおける出力を網羅的に含む、業務データ(業務文書やビジネスルール)が存在する
- **MC9:** 最終出力を絞り込むための基準があり、Enactment モデルとして構成することができる

MC6 は入力データの加工・変換作業は対象業務タスクに特化せずに実施できるという条件であり、AI 技術を業務タスクで簡易評価する際に重要となる。MC7 は業務タスクを実施するにあたって必要な情報の構造が明確であることと、その抽出が実現できることに関する条件である。MC8 は出力候補となる選択肢が業務全体をカバーしているという AI サービスアプリケーションの機能が合目的性を満たす条件となっている。MC9 は出力候補から出力を絞り込む際、統一した基準が存在するという条件となっている。

機械学習を用いたい AI サービスシステムを設計し、業務タスクに適用するにあたって、その適用可能性の評価は以下のように行う。まず、以下の 2 点を実施する。

- 対象業務タスクを分析し、MC1 から MC9 の条件を満たしているかどうかを判定する
- 満たしていない条件について、条件を満たさないことによる利用者

への影響を評価する

そして条件を全て満たす、または、満たさない条件について影響評価を実施していることをもとに、対象業務タスクに対して AI 技術を適用できると判断する。

4.2 生成 AI の適用可能性分析

前節で述べたように、業務は複数の業務タスクに分解され、担当者が 1 つ以上のタスクを実施していると考えられる。そして、ある業務について業務タスクに分解し、各タスクのモデル化を通して機械学習を活用した AI サービスの適用可能性を評価する手法を前節で提案した。しかし、業務を適切な粒度のタスクに分解することが困難な場合もある。そこで本節では生成 AI の適用可能性分析として、業務を直接分解するのではなく、業務で達成すべきことを分解し、それを実施するタスクを評価する。ここで、達成すべきことの分解手法として GQM+Strategies を活用する。

また、業務を構成するタスクにおける活動の内、何らかの知識を必要とする場面で生成 AI の利用が考えられる。業務タスクを進めるにあたって担当者は形式知だけでなく、暗黙知を持っている人とのやりとりを通して知識を得ることが多い。このような場面における生成 AI の活用では、LLM という暗黙知を持ち仲介知を発信する存在として位置付けられる。そこで、本研究では業務タスクを知識流通モデルとして表現することを行う。

そして、GQM+Strategies による分解でえられた達成したいことを実施するタスクを

知識流通モデルを通して評価し、生成 AI を利用するにあたって必要な条件を満たしているかどうかを評価する手法を提案する。

4.2.1 GQM+Strategies

GQM+Strategies は、企業が取り組みたい目標と戦略、そして目標の達成度を評価する指標を文書化とともにモデルとして表現する手法である [9]。本研究では、GQM+Strategies の中のゴール・ストラテジー分解を用いる。

ゴール・ストラテジー分解では、企業の目標(ゴール)と戦略(ストラテジー)の相互関係を明示する。ここで、ゴールとストラテジーは以下のように定義される。

- ゴール：将来達成したいと考えている期待される状態
- ストラテジー：目標を達成するための計画的なアプローチ

ストラテジーは「どうやってゴールを達成するのか」という問いに対する答えとなっているため、ゴールが与えられるとそれを達成することができるストラテジーを複数候補として関連付けることができる。実施するストラテジーについては成功を判断する必要がある。つまり各ストラテジーに対して、その成功という下位のゴールが関連付けられる。ストラテジーに関連付けられた下位のゴールがさらにいくつかのストラテジーによって達成される場合は、再度分解する。このように、ゴールとストラテジーを連鎖させて表現したものがゴール・ストラテジー分解となる。GQM+Strategies では通常、組織構造に沿ってゴールとストラテジーを分解・連鎖させていくが、本手法では組織構造は考慮せず、ゴールの達成手段が複数考えられる限り分解・連鎖の分析を続ける。そして、ストラテジーの成功(下位のゴール)が複数のストラテジーに分解されない段階で分析を終了する。

企業における戦略を ArchiMate でモデリングする試みは [34]で行われている。そこでは、ArchiMate の Goal 要素を分解し、分解された各ゴールに対して達成する手段として Requirement 要素を関連付けることでストラテジーを表現している。この手法に沿ってゴール・ストラテジー分解の結果を ArchiMate で表現すると図 9 となる。




図 9：ArchiMate を用いたゴール・ストラテジー分解の表現

こうして得られたゴール・ストラテジー分解木の末端のストラテジーを行う業務タスクにおいて次に述べる知識流通モデルを参照しながら評価する。

4.2.2 業務タスクの知識流通モデル

生成 AI は暗黙知・形式知を参照して実施する業務タスクに適用されると考えられる。そこで暗黙知・形式知を参照して実施する業務タスクの形式として以下の 2 種類を定義し、それぞれ検討する。

- **成果物創出型**：暗黙知・形式知を参照しながら成果物を作成する
- **成果物変換型**：直前の業務タスクの成果物を入力として、それを別の成果物に変換する

成果物創出型業務タスクには、レポート作成など具体的な成果物がないところから新規に成果物を作成するものが該当する。一方、成果物変換型業務タスクには、入力となる書類に対して何らかの判断結果を付与する審査系業務タスクや、仕様を入力としてモデルやプログラムを作成する開発系タスクなどが該当する。また、これらの2種類は排他的ではなく、成果物変換型の業務タスクの一部が成果物創出型で表されることもありうる。これらの2種類の業務タスクについて次のように知識流通モデルを考える。

成果物創出型業務タスクでは、通常は自身が持つ暗黙知を参照し、成果物を作成する。一方、新規または例外的な事項に対する活動では、暗黙知を拡張する必要がある。この拡張は知識の獲得と考えられる。知識の獲得に関してブートストラッピングプロセス (Bootstrapping Process) が提案されている [35]。ブートストラッピングプロセスでは、既存の知識に対してその利用を通して外部から知識の候補を得る。そして、それらと既存の知識との整合性をチェックした後知識として獲得する。このプロセスは人間の語彙獲得のモデル化 [36] に用いられており、またこの考えをもとに計算機上で類義語獲得を行う手法も提案されている [37]。ブートストラッピングプロセスで業務タスクを考えると、担当者は検索システムなどを通して形式知を調査し、業務関係者との対話を通して仲介知を得たのち、それらが正しいか、業務タスクの目的に合致するものかを評価する。そして必要な知識として暗黙知とする。こうして得られた拡張した暗黙知をもとに作業の成果物を作成する。この業務タスクを ArchiMate で知識流通モデルとして表現すると図 10 となる。




図 10：成果物創出型業務タスクにおける知識流通モデル

次に成果物変換型業務タスクでは、担当者が明示された依頼事項をもとに活動する。この活動は前節と同様に認知行動のモデルである OODA モデル [32]を用いると、「観測する」「整理する」「判断・決定する」「行動する」の活動に分解される。直前のタスクの出力である依頼事項を観測し、それを依頼事項に関する背景知識(暗黙知)をもとに理解する。この背景知識は依頼者が持っている暗黙知の一部となる。そのため、作業者は必要に応じて依頼事項に関する形式知や仲介知を参照する。この依頼事項に関する形式知や仲介知は依頼者側と作業者側の間で共通で利用できるものとする。理解した依頼事項を行動に移す際、行動のための背景知識の他に必要に応じて行動に関する形式知・仲介知を参照する。この行動に関する形式知や仲介知は作業者側のみに存在するものとする。こうして、行動する事項が決定した後、作業結果として成果物が作成される。この業務タスクを ArchiMate でモデル表現すると図 11 となる。




図 11：成果物変換型業務タスクにおける知識流通モデル

4.2.3 生成 AI の業務タスクへの適用評価

生成 AI を用いたサービスは、仲介知を提供する仲介者として働く。ここで前に述べた 2 種類の業務タスクの知識流通モデルをもとに、それぞれの業務タスクについて、生成 AI を用いたサービスに必要な条件を導出する。

企業のような組織では、形式知は業務文書のような形で作成され、企業内の検索アプリケーションによってアクセスできる。これに対して、仲介知は、組織内の個人を通じて獲得される。この仲介知は、生成 AI サービスを通じて獲得することが期待できるが、一般に、暗黙知や仲介知の正確性は保証されていない。よって、成果物作成型業務タスクの場合、以下の条件が知識流通モデルから導かれる。

- GC1： 仲介知を提供する仲介者と利用者は入力（生成 AI サービス

の場合プロンプトの内容)を共有できる

- **GC2:** 仲介知の整合性や有用性を検討するのに十分な暗黙知を利用者が持つ
- **GC3:** 提供された仲介知の正確さを容易に検証できる

一方、成果物変換型業務タスクの場合、前述の条件に加え、以下の条件が図 11 のモデルから導かれる。

- **GC4:** 要求に関する仲介知が不正確または不十分な場合、依頼側に確認することでき、必要な場合依頼内容を修正できる

ゴール・ストラテジー分解で得られた各末端のストラテジーについて、それを実施する業務タスクを上記の 2 分類から同定し、その後、知識流通モデルと条件 (GC1, …, GC4) を参照し、業務タスクに生成 AI サービスを適用できるかを評価する。

5 章 事例分析による評価

5.1 AI サービスシステムの適用可能性分析手法の評価

機械学習を中心とした AI 技術を適用したサービスシステムについて、様々な業務での適用例が検討されている。本実験では、実際にアプリケーションとして稼働している IT 管理業務、保険金支払い業務、顧客対応センター業務におけるユースケースを対象とした。対象とした 6 ユースケースについて業務名と AI サービスシステムが適用される業務タスクを表 5 に示す。これら T1~T6 で示した業務タスクに対して提案手法で導出した条件 (MC1~MC9) の評価を行う。

表 5：対象ユースケース

	業務	業務タスク
T1	ITシステム管理業務	ITサービスに関するテキスト形式の問い合わせへ回答する作業
T2	部品管理業務	画像の中から対象部品を識別し商品情報を提供する作業
T3	手続き処理業務	外部からの依頼を最適な事務手続きに振り分け実行する作業
T4	保険金支払い業務	保険請求から、支払い内容を決定する作業(支払い査定)
T5	顧客対応センター業務	顧客の問い合わせを聞き、最適な担当者を割り当てる作業
T6	顧客対応センター業務	問い合わせメールから、サポートチケットを作成する作業

表 5 に示した業務タスクでは、AI 技術を利用したサービスシステムが実現され、すでに稼働している。そこで、本研究で提案した適用可能

性の評価に関する条件について、T1~T6 の業務タスクが満たしているかどうかを分析した。表 6 に分析結果を示す。

表 6：AI サービスシステムの適用可能性分析方法による評価結果

	MC1	MC2	MC3	MC4	MC5	MC6	MC7	MC8	MC9
T1	○	○	○	✖	○	n/a	○	○	○
T2	○	○	○	✖	○	n/a	○	○	○
T3	○	○	○	○	○	○	○	○	○
T4	○	○	○	○	○	○	○	○	○
T5	○	○	○	○	○	○	○	○	○
T6	○	○	○	✖	○	○	○	○	○

T1、T6 では入力文書の分類、T2 では画像からの部品の検出を Resolution コンポーネントで行うが、そこで用いる特徴量を中間生成物として明示的に提示されることは少ないと考えられる。つまり、Assessment コンポーネントと Resolution コンポーネントが一体化した AI エンジンが使用されている。したがって、T1、T2、T6 では MC4 が満たされないと評価した。また、T1、T2 ではシステムへの入力(Facts)となる問い合わせテキストや画像が、Transformation コンポーネントが出力するビジネスオブジェクト(Perceptions)そのものとなる。そのため、C6 の評価は不要(n/a)と判断した。

5.2 生成 AI の適用可能性分析手法の評価

ここでは、生成 AI の適用可能性分析手法の有効性を確認するために行った、事例評価について述べる。対象領域として保険会社における事務管理業務を選択し、コスト削減を最上位ゴールとした。まず GQM+Strategies のゴール・ストラテジー分解により、図 12 に示す分解木が得られた。




図 12：ゴール戦略木による分析結果

分解木の末端のストラテジーである S1-3、S2-2、S3-1、S3-2、S3-3 について、業務タスクの種類を特定し、条件 AC1～AC4 を満たすかどうかを評価した。評価結果を表 7 にまとめる。

表 7：生成 AI の適用可能性分析方法による評価結果

	S1-3	S2-2	S3-1	S3-2	S3-3
Type	n/a	成果物創出型	成果物創出型	成果物創出型	成果物変換型
GC1	n/a	○	より詳細な評価分析が必要	○	○
GC2	n/a	○	×	○	○
GC3	n/a	○	×	○	○
GC4	n/a	n/a	n/a	n/a	より詳細な評価分析が必要

S1-3 は仲介知を恒常的に参照する業務タスクではないと判定されるため、適用評価の対象から外れる。S2-2 および S3-2 では、生成 AI を用いたサービスを業務タスクに効果的に使用できると評価される。一方、S3-3 については C4 についてさらなる評価が必要であることがわかった。また、S3-1 で生成 AI を業務タスクで直接使用する場合、いくつかのリスクがあることがわかる。

6 章 考察

まず AI サービスシステムの適用可能性分析について提案手法の考察を行う。評価実験の結果から、AI サービスシステムが実用化されている業務タスクは本研究で提案した適用可能性の条件のほとんどを満たしていることがわかった。提案手法した MC1～MC9 の条件は AI 技術を業務タスクに適用するための必要条件になっていると考えられる。よって提案手法が研究課題 **RQ1** の解決策の 1 つになりえることが確認された。

ただし、業務タスクの入力について、書類のような文書データから業務タスクに必要な部分の切り出しや、音声からテキストへといったデータ変換を必要とせず、システムへの入力を、そのままの形で、業務タスクで利用することがある。そのようなケースでは MC6 は評価不要 (n/a) として必要条件から外すことが可能だと考えられる。また、文書や画像の分類の場合、対象業務で定義された選択肢(分類先)に認知した結果(Perceptions)を分類する。機械学習を用いた分類エンジンでは、分類のための特徴量(Hypotheses)は内部変数として保持され外在化されていることはなく、Assessment コンポーネントと Resolution コンポーネントが一体化している。このようなケースでは MC5 を満たすことで業務タスクを行う担当者が十分対処できれば、MC4 が満たされなくても問題ない。つまり、MC4 が満たされない場合、対象業務タスク

が認知結果を所与の選択肢に分類する活動であるかどうかを判定することで適用可能性を評価することができる。

AI 技術の適用を検討する業務タスクを分析し、本研究で提案した条件を満たしていない場合は、AI サービスシステムの実現が難しいと判断することができる。しかしながら、適用可能性を満たさない場合、満たされていない条件を示すことができるが、その条件を満たさないことで、実現時にどのような課題をもたらすのかといったことが起きる。この点は本研究の提案手法では説明できない。これに関しては、本研究で提案した条件と AI サービスシステムに求められる品質特性を関連づけることで解決できると考えられる。これは今後の課題である。また、対象となる業務タスクを分析し、提案した条件を満たした場合でも、適用可能性が高いことがわかるが、適用可能な AI エンジン（機械学習モジュール）の選択は本研究の範囲外となっている。実プロジェクトで本手法利用を考えた場合、適用可能性の判定とともに、候補となる AI エンジンが絞り込まれることは有用である。具体的な AI サービスシステムの設計に向けた提案手法の拡張も今後の課題である。

次に、生成 AI の適用可能性分析について提案手法の考察を行う。分析例から、特に外部からの問い合わせに自動的に対応する (S3-1) ためには、リスクの回避など生成 AI を用いたサービスの設計を慎重に行う必要がある。これは、外部の問い合わせ者は生成 AI を通して得た仲介知の正確性などを十分に評価できる保証がないからである。一方、管理部門のオペレーターによる問い合わせ対応（いわゆる照会応答）の支援ツールとして生成 AI を利用すること (S3-2) ができる。これは、生成 AI を通して得られた仲介知をオペレーターが最終的に回答に用いる際に、必要があれば正確性を確認する体制を作ることが期待できるからである。さらに、文書処理を半自動化するために生成 AI を活用できること (S3-3) もわかった。

例えば、診断書に基づく保険金の支払査定などの文書処理は、最終的な確認プロセスを専門家が人手で実施することで AC4 を満たすため、半自動化すること期待できる。実際に機械学習を用いた保険金の支払い査定サービスシステムは、いくつかの保険会社に導入されている大幅な人件費の削減ができたと報告されている²。実施例で得られた分析結果より、本研究で導出した条件は生成 AI の業務適用可能性の必要条件と考えられる。よって提案手法が研究課題 **RQ2** の解決策の 1 つになりえることが確認された。

² AI を用いた保険金の支払い査定サービスとその効果

<https://artificial.io/company/blog/ai-for-commercial-underwriting-how-its-already-making-a-difference>

一方、提案手法では、ゴール・ストラテジー分解の分析において分解を停止するための基準は考慮されていない。また、各分解レベルにおけるストラテジーの粒度は分析者に依存する。また、業務タスクの種類を識別するための基準も必要である。これらが本研究の限界であり、今後の課題である。

7 章 まとめ

本研究では、オフィス業務に AI 技術を適用することを対象とした。近年、機械学習技術を活用した AI サービスシステムの業務適用だけでなく、ChatGPT のような LLM を用いた生成 AI の急速な進化により、様々なビジネス領域においてその適用の検討が進んでいる。しかしながら、AI 技術の業務適用可能性の分析については、事業部門の経験やスキルに依存する状況があった。またデータサイエンティスト人材の不足から機械学習をはじめとした AI の要素技術に関する知識や洞察が十分でない担当者であっても適用可能性の分析を担える必要があった。

そこで、業務を構成する業務タスクに対する機械学習や生成 AI を用いたサービスシステムについて、その適用可能性を評価するための業務分析受法を提案した。そして、保険業界を中心とした実業務で実現されているユースケースを対象とした評価や、保険事務業務に提案手法を適用した実施例を行った。その結果、提案した 2 つの手法のそれぞれに示した条件が AI サービスシステムを業務タスクに適用するための必要条件となることがわかった。保険業務は多岐にわたるため、その多くの領域での検証を通して、今回検討した手法を開発現場に広く適用できるよう拡張することが今後の課題である。

参考文献

- [1] 藤堂, “最先端の AI の利用と応用,” *人工知能*, 33(2), pp. 192-106, 2018.
- [2] 山口, “実践知能・多重知能のためのメタ AI アーキテクチャ,” *人工知能*, 32(6), p. 983-987, 2017.
- [3] F. Kumeno, “Software Engineering Challenges for Machine Learning Applications: A Literature Review,” *Intelligent Decision Technologies*, 13, pp. 463 - 476, 2019.
- [4] L. E. Lwakatare, A. Raj, B. Jan, O. H. Helena , I. Crnkovic,

- “A Taxonomy of Software Engineering Challenges for Machine Learning Systems: An Empirical Investigation,” *Proceedings of the 20th International Conference on Agile Software Development (XP)*, 2019, pp. 227 – 243.
- [5] 丸山 , 城戸, “機械学習工学へのいざない,” *人工知能*, 33(2), pp. 124-131, 2018.
- [6] 石川, 丸山, 柿沼, 竹内, 土橋, 中川, 原, 堀内 , 鷺崎, 機械学習工学, 講談社, 2021.
- [7] H. Takeuchi , S. Yamamoto, “Business AI Alignment Modeling Based on Enterprise Architecture” , *Proceedings of the 11th International Conference of Intelligent Decision Technologies*, p. 155-165, 2019.
- [8] H. Takeuchi , S. Yamamoto, “AI Service System Development Using Enterprise Architecture Modeling,” *Proceedings of the 23rd International Conference on Knowledge-Based and Intelligent Information & Engineering Systems*, p. 923-932, 2019.
- [9] V. Basili, A. Trendowicz, M. Kowalczyk, J. Heidrich, C. Seaman, J. Münch , D. Rombach, *Aligning Organizations Through Measurement: The GQM+Strategies Approach*, Springer International Publishing, 2014.
- [10] IEEE Transmitter, “10 Users of AI in Everyday Life,” 2022. Available: <https://transmitter.ieee.org/10-uses-of-ai-in-everyday-life/>.
- [11] H.-M. Chen, R. Kazman , S. Haziye, “Strategic Prototyping for Developing Big Data Systems,” *IEEE Software*, 33(2), pp. 36-43, 2016.
- [12] M. Kim, Z. Thomas, R. DeLine , A. Begel, “The Emerging Role of Data Scientists on Software Development Teams,” *Proceedings of the 38th International Conference on Software Engineering*, pp. 96-107, 2016.
- [13] I.-Y. Song , Y. Zhu, “Big data and data science: what should we teach?,” *Expert Systems*, 33(4), pp. 364-373, 2016.
- [14] S. Amershi, A. Begel, C. Bird, R. DeLiner, H. Gall, E. Kamar, N. Nagappan, B. Nushi , T. Zimmermann, “Software Engineering for Machine Learning: A Case Study,”

Proceedings of the 41st International Conference on Software Engineering, pp. 291-300, 2019.

- [15] 岡野原, 大規模言語モデルは新たな知能か -- ChatGPT が変えた世界, 岩波書店, 2013.
- [16] 鈴木, 神谷, “ChatGPT によるプログラミング授業の課題の解答生成の評価,” *信学技法*, SS2023-10(2023-07), 2023.
- [17] J. Camara, J. Troya, L. Burgueo, A. Vallecillo, “On the assessment of generative AI in modeling tasks: an experience report with ChatGPT and UML,” *Software and Systems Modeling*, 22, pp. 781-793, 2023.
- [18] H.-G. Fill, P. Fettke, J. Köpke, “Conceptual Modeling and Large Language Models: Impressions From First Experiments With ChatGPT,” *Enterprise Modelling and Information Systems Architectures*, 18(3), pp. 1-15, 2023.
- [19] The Open Group, ArchiMate 3.1 - A Pocket Guide, Van Haren Publishing, 2019.
- [20] M. Vicente, N. Game, M. M. d. Silva, “A Design Theory Nexus for Situational Enterprise Architecture Management,” *Proceedings of the 4th International Conference on Exploring Service Science*, pp. 86-99, 2013.
- [21] N. Mayer, J. Aubert, E. Grandry, C. Feltus, E. Goettelmann, R. Wieringa, “An integrated conceptual model for information system security risk management supported by enterprise architecture management,” *Software & Systems Modeling*, pp. 1-28, 2018.
- [22] H. Takeuchi, S. Yamamoto, “Method for Assessing the Applicability of AI Service Systems,” *Proceedings of the 13th International Conference on Human Centered Intelligent Systems*, p. 323-334, 2020.
- [23] T. O. Group, ArchiMate 3.1 - A Pocket Guide, Van Haren Publishing, 2019.
- [24] R. J. Sternberg, *Successful Intelligence: How Practical and Creative Intelligence Determines Success in Life*, Simon & Schuster, 1996.
- [25] M. Chui, J. Manyika, M. Miremadi, N. Henke, R. Chung, P. Nel, S. Malhotra, “Notes from the AI frontier insights from hundreds of use cases,” 2018. [オンライン].

- Available: <https://www.mckinsey.com/featured-insights/artificial-intelligence/notes-239-from-the-ai-frontier-applications-and-value-of-deep-learning>.
- [26] 広. 竹内, 修. 山本, 史. 秋原, 旬. 石井, 勇. 岡原, 史. 星野, “金融機関における AI 実践プロジェクトの分析とプロジェクト管理への活用,” *情報処理学会デジタルプラクティス*, 第 10, 第 3, pp. 560-575, 2019.
 - [27] J. Devlin, M.-W. Chang, K. Lee, K. Toutanova, “BERT: Pre-training of Deep Bidirectional Transformers for Language Understanding,” *Proceedings of NAACL-HLT*, pp. 4171 - 4186, 2019.
 - [28] A. Radford, K. Narasimhan, T. Salimans, I. Sutskever, “Improving Language Understanding by Generative Pre-Training,” 2018. Available: https://cdn.openai.com/research-covers/language-unsupervised/language_understanding_paper.pdf.
 - [29] L. Ouyang et al., “Training language models to follow instructions with human feedback,” 2022. Available: <https://arxiv.org/pdf/2203.02155>.
 - [30] 野中, 竹中, 知識創造企業, 東洋経済新報社, 2020.
 - [31] 山本, CMC で変わる組織コミュニケーション, NTT 出版, 2010.
 - [32] K. Baclawski, E. S. Chan, D. Gawlick, Z. H. Liu, A. Ghoneimy, K. Gross, X. Zhang, “Framework for Ontology-Driven Decision Making,” *Applied Ontology*, 12(3-4), pp. 245 - 273, 2017.
 - [33] D. Gawlick, E. S. Chan, A. Ghoneimy, Z. H. Liu, “Mastering Situation Awareness: The Next Big Challenge?,” *SIGMOD Record*, 44(3), p. 2015, 19-24.
 - [34] A. Adinaand, M.-E. Iacob, J. v. Hillegersberg, D. Quartel, L. Bodestaff, H. Franken, “Modeling strategy with ArchiMate,” *Proceedings of the 30th Annual ACM Symposium on Applied Computing*, pp. 1211-1218, 2015.
 - [35] S. Carey, The Origin of Concepts, Oxford University Press, 2011.
 - [36] M. Imai, S. Kita, “The Sound Symbolism Bootstrapping Hypothesis for Language Acquisition and Language Evolution,” *Philosophical Transactions of the Royal*

Society B, 369(1651), p. 2014.

- [37] M. Thelen , E. Riloff, “A Bootstrapping Method for Learning Semantic Lexicons using Extraction Pattern Contexts, ” *Proceedings of the ACL Conference on Empirical Methods in Natural Language Processing*, pp. 214-221, 2002.