

Title	DXにおける機械学習応用システムの深化プロセスと人間・機械協働型マネジメント
Author(s)	奥田, 聡
Citation	
Issue Date	2024-09
Type	Thesis or Dissertation
Text version	ETD
URL	http://hdl.handle.net/10119/19380
Rights	
Description	Supervisor: 内平 直志, 先端科学技術研究科, 博士

博士論文

DX における機械学習応用システムの深化プロセスと
人間・機械協働型マネジメント

奥田 聡

主指導教員 内平 直志

北陸先端科学技術大学院大学
先端科学技術専攻
[知識科学]

令和6年9月

Abstract

This doctoral dissertation focuses on machine learning systems and human-machine collaborative management, elucidating digital transformation's (DX) classification and evolutionary processes and methods for enhancing DX implementation intention. Promoting DX within enterprises is essential for improving operational efficiency and creating new value, with machine learning systems playing an increasingly crucial role. However, significant challenges exist in how users can effectively utilize machine-generated outputs and exploit the system. This research aims to classify DX in enterprises, clarify its evolutionary processes, and investigate how machine learning systems, including human factors, interact, exploit, and collaborate.

This study proposes a new theoretical framework based on systematic analysis of qualitative data to address the challenges enterprises face with DX and machine learning application systems. The factors that enhance DX intention and the human-machine collaboration factors were validated through quantitative analysis.

The research results, which unveil three classifications of DX in enterprises (internal chain optimization DX, value chain optimization DX, and new business value creation DX) and their evolutionary patterns (operational excellence, self-sufficiency, and co-creation), are of significant importance. The findings shed light on the factors that influence DX intention, such as attitudes, interests, and confidence in skills and abilities related to DX. Moreover, the systematic enhancement of these factors can improve the intention.

The exploitation process of machine learning systems is a continuous sequence evolving from data visualization to system autonomy, with each stage characterized by specific features and challenges. These challenges include technical issues and human factors, where users must accept, adapt, and effectively utilize the system. The construction of trust in human-machine collaboration is crucial, with the dissertation analyzing the elements required for trust and the processes leading to it. Translators, who interpret and convey machine-generated predictions and analyses, are critical in optimizing system performance and fostering user trust by presenting the system's output efficiently.

The dissertation identifies characteristic user profiles (general users, AI users, AI translators) at each stage of the machine learning system's exploitation process. It

highlights the factors influencing user trust in machines and aims to provide guidelines for incrementally deepening machine learning systems in alignment with the evolution of DX. The study emphasizes the importance of human trust in machines within the knowledge-creation process, where machines function as active agents. This balanced relationship is crucial for the successful integration of humans and machines in promoting DX in enterprises.

By complementing and adapting to each other, humans and machines can offer significant insights into promoting DX in enterprises. Companies can overcome the complexities of technology and innovation management through this integrated approach, ensuring continuous improvement and competitive advantage in the digital era.

Keywords: Human-machine collaboration, Software Engineering for Machine Learning Applications, Digital Transformation, Business Model Innovation, Project Management, Technology and Innovation Management.

概要

本博士論文は、機械学習応用システムと人間・機械協働型マネジメントに焦点を当て、デジタルトランスフォーメーション（DX）の分類とその進化過程、および DX 実行意思の向上方法を明らかにする。企業における DX 推進は、業務効率の向上や新たな価値創造に不可欠であり、その中で機械学習応用システムは重要性を増している。半面、機械による出力をユーザーがどのように活用し、システムを深化させていくかには多くの困難が存在する。本研究の目的は、企業の DX を分類の上その進化過程を明らかにし、人間系を含む機械学習応用システムがどのように相互作用し、深化・協働するのかを明らかにすることである。本研究では質的なデータに基づいて体系的な分析を行い、企業が直面する DX と機械学習応用システムの課題に対する新たな理論的枠組みを提案した。DX 実行意思を高める要素と人間・機械協働因子は量的分析によりモデルの立証を行った。

研究結果から、企業における DX3 分類（内部チェーン最適化型、バリューチェーン最適化型、新事業価値創造型）と、それらの進化パターン（オペレーションエクセレンス型、自己充足型、共創型）を示した。また、DX に対する態度・興味及びスキルや能力に関する自信が高いと DX 実行意思が高くなることが明らかになり、これらの要素を高めることで実行意思を計画的に向上させることができることがわかった。

機械学習応用システムの深化プロセスは、データの可視化からシステムの自律へと深化する連続的な過程であり、各段階での特徴と困難を解明する。これらの困難にはテクニカルな課題と、ユーザーがシステムを受容し、変容しながら利活用する人的な課題が存在していることが分かった。人間・機械の協働においては、信頼の構築が重要であり、信頼に必要な要素と信頼に至るプロセスを分析し、機械による予測や分析結果を解釈し伝達する翻訳者の役割が重要であることを示した。これにより、システムの出力をユーザーにとって理解しやすい形で提示し、機械の情報価値を最大化し、ユーザーの信頼を促進することが重要である。人間が機械を信頼する因子も機械学習応用システムの深化プロセスのステージごとに示しそれぞれ特徴的なユーザー像（一般的なユーザー、AI 活用户、AI 翻訳者）を明らかにした。

本博士論文は、DX の進化に合わせて、人間と協働しながら機械学習応用システムを段階的に深化させるためのガイドラインを提供することを目指す。機械学習応用システムの深化プロセスにおける人間・機械協働は、人間が機械を信頼することが重要であり、知識創造プロセス内で機械が 1 つの主体として機能する。人間と機械が互いに補完し合い、相互適応することで、企業における DX を推進するための重要な知見を提供する。この統合されたアプローチを通じて、企業は技術とイノベーション管理の複雑さを克服し、デジタル時代における継続的な改善と競争優位を確保できる。

Keywords: Human-machine collaboration, Software Engineering for Machine Learning Applications, Digital Transformation, Business Model Innovation, Project Management, Technology and Innovation Management.

目次

博士論文.....	1
1. 序論	1
1.1. 研究の背景	1
1.2. 研究の目的とリサーチ・クエスチョン.....	6
1.3. 研究の方法	7
1.4. 用語の定義	9
1.5. 本論文の構成	12
2. 先行研究レビュー	15
2.1. デジタルトランスフォーメーションに関する先行研究.....	15
2.2. デジタルトランスフォーメーション分類に関する先行研究.....	16
2.3. ソフトウェア工学に関する先行研究	18
2.4. 機械学習工学に関する先行研究	20
2.5. 機械学習応用システムのプロジェクトマネジメントに関する先行研究....	24
2.6. 人間・機械協働に関する先行研究	25
2.7. システム深化に関する先行研究	29
2.8. 先行研究の課題と本研究の位置づけ	31
3. デジタルトランスフォーメーション 3 分類と進化過程	34
3.1. DX と機械学習応用システム	34
3.2. 事例研究の目的	36
3.3. 研究方法	37
3.4. DX3 分類と主要活動.....	41
3.5. DX3 分類の特徴.....	54
3.6. DX の進化過程と進化パターンの分析.....	60
3.7. 小括	62
4. DX 実行意思.....	63
4.1. DX 実行意思の研究目的とアプローチ	63
4.2. DX 実行意思の一次分析.....	63
4.2.1. 研究方法	63
4.2.2. 分析方法とデータ品質	65
4.2.3. 研究結果と分析	67

4.3.	DX 実行意思の二次分析	69
4.3.1.	研究方法	69
4.3.2.	分析方法とデータ品質	71
4.3.3.	研究結果と分析	74
4.4.	一次分析と二次分析の関係	76
4.5.	小括	78
5.	機械学習応用システムの深化プロセス	79
5.1.	機械学習応用システムの深化プロセス.....	79
5.2.	事例研究の目的と研究方法	83
5.3.	テーマティック・アナリシス法による分析結果.....	88
5.4.	機械学習応用システムの深化プロセスの特徴と困難.....	89
5.4.1.	可視化	90
5.4.2.	人間中心 ML 補助	93
5.4.3.	ML 中心人間補助.....	95
5.4.4.	自律	98
5.4.5.	他アクターの役割	99
5.5.	人間・機械協働	100
5.6.	本章の分析	105
5.6.1.	機械学習応用システムの深化プロセスの分析.....	105
5.6.2.	人間・機械協働における分析	108
5.7.	小括	113
6.	考察	115
6.1.	統合的考察	115
6.2.	先行研究との関係性	118
7.	結論	123
7.1.	本研究のまとめ	123
7.2.	リサーチ・クエスチョンに対する回答.....	125
7.3.	理論的貢献	127
7.4.	実務的貢献	128
7.5.	本研究の限界と将来研究への示唆	129
	参考文献	131
	備考	136
	A1.3 章コードシステム	136
	A2.3 章インタビューデータとコード	137
	B1.4 章2 節アンケート項目	141
	B2.4 章3 節アンケート項目	147

C1.5 章コードシステム	150
C2.5 章インタビューデータとコード	151
謝辞	156
研究業績リスト	158

図目次

図 1-1 DX の取組状況	1
図 1-2 IoT・AI 等のシステム・サービスの導入状況	2
図 1-3 DX を進める際の課題	2
図 1-4 DX の取り組み内容と成果	4
図 1-5 従来と異なるソフトウェア開発手法	6
図 1-6 本博士論文の研究手法	9
図 1-7 論文構成と研究方法の対応関係	14
図 2-1 先行研究の検討範囲	15
図 2-2 デジタイゼーション, デジタライゼーション, デジタルトランスフォーメーション	17
図 2-3 機械学習ワークフローの 9 つの段階 (The nine stages of the machine learning workflow)	22
図 2-4 ML パターン名	23
図 2-5 人間と AI の協働意思決定のレベル (Levels of human-AI collaborative decision making)	26
図 2-6 ミッシングミドル	27
図 2-7 スマートコネクテッドプロダクトの深化プロセス (Capabilities of Smart Connected Products)	29
図 2-8 先行研究の課題と本研究の位置づけ	33
図 3-1 研究の流れ	37
図 3-2 DX3 分類	42
図 4-1 研究の流れ	63
図 4-2 第一次 DX 実行意思モデル仮説	64
図 4-3 第一次 DX 実行意思モデルの分析結果	68
図 4-4 第一次 DX 実行意思モデル	68
図 4-5 研究の流れ	69
図 4-6 第二次 DX 実行意思モデル仮説	70
図 4-7 第二次 DX 実行意思モデルの分析結果	75
図 4-8 第二次 DX 実行意思モデル	76
図 4-9 第一次 DX 実行意思モデルと第二次 DX 実行意思モデルの違い	77
図 5-1 機械学習応用システムの深化プロセス	80
図 5-2 機械学習応用システムの深化プロセスと人間・機械のモード	82
図 5-3 事例研究対象プロジェクトの位置付け	84
図 5-4 QAML ニーズマップ・技術シーズ・施策	86

図 5-5 研究の流れ.....	87
図 5-6 機械学習応用システムの特徴と困難.....	90
図 5-7 機械学習応用システムの深化プロセスのステージ別のコード出現率.....	101
図 5-8 機械学習応用システムの深化プロセスのステージ別の人間機械協働因子..	111
図 6-1 各章における研究方法と考察の対応	115
図 6-2 DX 進化過程における必要要素	116
図 6-3 人間機械協働因子と DX 分類の関係性.....	118
図 6-4 人間・機械協働を含んだ知識科学の対象.....	121

表目次

表 2-1 パターン要素.....	20
表 2-2 人間・コンピューターインタラクション、人間・機械インタラクション、人間・機械協働、人間・機械チームング.....	28
表 2-3 スマートコネクテッドプロダクトの4機能と事例	30
表 3-1 DX のキーワードと分類	35
表 3-2 講演対象者.....	38
表 3-3 講演・質疑応答日時.....	39
表 3-4 講演依頼内容.....	39
表 3-5 テーマ、コードとサブコード.....	41
表 3-6 DX3 分類の特徴と講演者対応表	56
表 3-7 講演者の DX3 分類と特徴.....	58
表 3-8 新規事業創造方法論.....	59
表 3-9 DX 進化過程	61
表 3-10 DX 進化パターン	61
表 4-1 アンケート対象者.....	65
表 4-2 R-Square 値	66
表 4-3 Cronbach' s alpha 値及び AVE 値	66
表 4-4 アンケート対象者のスクリーニング条件.....	70
表 4-5 第二次因子別回答情報統計.....	71
表 4-6 第二次 R-Square 値.....	72
表 4-7 Cronbach' s alpha 値及び AVE 値	73
表 4-8 因子間標準偏差・T 検定・p 値.....	73
表 5-1 機械学習応用システムの深化プロセス.....	80
表 5-2 機械学習応用システムの深化プロセスの特徴.....	81
表 5-3 インタビュー対象者.....	85
表 5-4 インタビュー設問表.....	86
表 5-5 事例研究対象プロジェクトの深化プロセス.....	88
表 5-6 機械学習応用システムの深化プロセスの特徴と困難のソース対応表.....	89
表 5-7 人間・機械協働のソース対応表.....	102
表 5-8 人間・機械協働の特徴の出現数	103
表 5-9 機械学習応用システムの深化ステップの次ステップに至る条件.....	107
表 5-10 AI との信頼構築に影響を与える要素	109
表 5-11 HMC factor の T 検定	109
表 5-12 HMC factor の成分行列	112


表 5-13 人間・機械協働のユーザー像.....	113
表 6-1 事例研究対象プロジェクトの機械学習応用システムの深化プロセス.....	117
表 6-2 Ergonomics と Applied human factors.....	120
表 6-3 知識科学観点における人間・機械協働プロセスの研究.....	122

1. 序論

本章では、デジタルトランスフォーメーション（以下、DX）及び機械学習応用システムについての研究に取り組むに至った背景について記述する。研究の目的とリサーチ・クエスチョンを定義し、本研究の研究手法と対象とする領域について述べる。

1.1. 研究の背景


近年、多くの企業は競争力を高めるために DX（Stolterman and Fors 2004）を推進する方法を模索している。情報通信白書（総務省 2020）によると DX を実施してる企業は全体では 22.8%であり、この数年間で多くの大企業及び中小企業が実施に向けて取り組んでいる（図 1-1）。



((総務省 2020) 情報通信白書より筆者作成)

図 1-1 DX の取組状況


これらは機械学習、クラウドコンピューティング、インターネット・オブ・シングズ (IoT) といったビッグデータ活用のための技術進化に伴うところが多い。総務省の調べでは、IoT・AI 等のシステム・サービスの導入状況（図 1-2）は、「導入している」が 14.1%、「導入していないが導入予定がある」が 9.8%となっており技術の導入が組織にとって進行中のプロセスであることがわかる（総務省 2020）。



((総務省 2020) 情報通信白書より筆者作成)

図 1-2 IoT・AI 等のシステム・サービスの導入状況

DX の推進や新たな技術群は企業経営に大きな影響を与えており、工場や物流施設からのインターネット・オブ・シングズ (IoT) からのデータや、販売・マーケティング現場での顧客活動履歴の分析によって、企業は顧客体験 (Customer Experience, CX) の向上や迅速な意思決定と労働量削減を実現している。一方で、業務のデジタル化に伴うスタッフのデジタルリテラシーの向上、変革に対する社員の抵抗や文化・業界慣習による障壁など、多くの課題がある (図 1-3)。



((総務省 2020) 情報通信白書より筆者作成)

図 1-3 DXを進める際の課題

DXを進めていくうえでは、「顧客や社会の問題の発見と解決による新たな価値の創出」と「組織内の業務生産性向上や働き方の変革」という二つのアプローチを同時並行に進め

ることが重要（IPA 2023）である。DX を推進するうえで、しばしばデジタルイゼーション、デジタルライゼーション、デジタルトランスフォーメーションと分けられる。国内および米国の企業の DX の取り組み状況を図 1-4 に示した。アナログ・物理データのデジタル化はデジタルイゼーションを指すが国内では 16.5%の企業が実施している。業務の効率化による生産性の向上はデジタルライゼーションと言い換えることができ、国内では 11.9%の企業が実施している。最後に新規製品・サービスの創出や顧客起点の価値創出によるビジネスモデルの抜本的な変革はデジタルトランスフォーメーションと言い換えることができ、それぞれ 6.9%、6.4%が実施している。デジタルイゼーションの導入度が高く順次ステップが進展するごとに取り組み成果が下がっていることがわかる。

ここでの DX の成果を実例で上げていきたい。デジタルイゼーションは小売店における会員登録用紙にエンドユーザーが記述した情報を紙で保存せず、デジタル化することである。アナログでは用紙回収をしてからのデータ活用が難しいが、デジタル化するうえでは用紙回収後、パンチャーによるデータ入力が必要となる。これにより e-メールや郵便によるダイレクトメールの送付が可能となりキャンペーン効果の向上が可能である。デジタルイゼーションでは、上記の例でいえば、以下のような処理が想定できる。データに対して e-メールを送付する際に、会員情報のセグメント化、キャンペーン情報の策定、e-メールの送信、顧客のアクション状態の分析、より効率的なキャンペーン情報や e-メールの送信時間の試行錯誤するプロセスがある。ここでは各処理においてアプリケーションログを取りプロセスマイニングをすることにより、どの処理に時間がかかっているかを分析することでリソースの最適化が可能となる。デジタルトランスフォーメーションでは、エンドユーザーへモバイルアプリケーションを提供することで、コーヒーのサブスクリプションサービスを販売する等、新たな顧客価値を提案しビジネスモデルを変えることにある。

デジタルイゼーション、デジタルライゼーション、デジタルトランスフォーメーションの分類は DX を推進するにあたってアナログデータのデジタル化や業務プロセスにデジタルを介在させることステップは示しているが、複雑化しているバリューチェーンで社内外の様々なアクターがいる点やデータをいかに活用すべきかは示されておらず、本論文の研究動機の 1 つとなっている。





図 1-4 DX の取り組み内容と成果

DX の推進においてデジタルをいかに経営に取り込んでいくかは重要なテーマである。ただし、DX 推進において DX、AI、ビッグデータの必要性は理解されるが、その運用においては様々な課題がある。本研究の動機は筆者が普段の仕事において直面する課題に由来する。機械学習応用システムの開発とその実用化において、ユーザーが実際に利用することが極めて重要である。しかし、機械学習は必ずしも期待通りに動作するわけではなく、その結果、ユーザーが機械学習応用システムを敬遠する事例がしばしば見受けられる。機械学習応用システムを実際に使用する際の障壁を低減し、ユーザーの利用率を上げるとはシステム計画の達成と投資対効果の向上も期待できる。またユーザーの利用率向上はデータコレクションにもつながり、機械学習の精度向上にもつながる。機械学習応用システムへの投資は一過性のものではなく、その後更なる投資を行うことで更なる機能を拡張することができ、これにより機械学習応用システムの深化が実現する。これによりまたシステムの魅力が高まりユーザーの利用率が上がるというスパイラルな現象が重要である。ただし、このスパイラルが逆回転することもあり、ユーザーの利用率が上がらず、システム投資対効果が確認できず、データコレクションが不完全のため機械学習の精度は低下し、結果機械学習応用システムがそれ以上の深化をせずに役目を終えてしまう場合もある。スパイラルが良いほうに作用するか悪いほうに作用するかは、機械学習応用システムに関わる人と機械の関係性にあると考えた。

企業の DX 推進において、ビッグデータを処理する機械学習応用システムの活用は非常に重要である。しかし、従来の IT システムの開発で一般的なウォーターフォール型ソフトウェア開発モデル (Balaji and Murugaiyan 2012) とは異なった開発プロセスが必要であり、多くの新たな問題が浮上している。機械学習応用システムの開発はウォーターフォール型開発、つまり演繹的なソフトウェア開発とは異なり帰納的ソフトウェア開発が特

徴である（図 1-5）。これらの問題に対処する機械学習に関するソフトウェアエンジニアリングである SEMLA (Software engineering for machine learning applications) の研究が活発になっている。Amershi (2019) は Microsoft が開発プロセスに機械学習を統合する方法として AI ワークフローの 9 ステップを提案し、データ管理やモデルカスタマイゼーションなど AI エンジニアリングに固有の課題を特定した。機械学習応用システムは一度開発をして終了ではなく、継続的に「深化」することが多く、「深化プロセス」とは複数のフェーズでシステム開発を漸進的に行うことを指す。従来のソフトウェアシステムもメンテナンスを通じて機能的な改善を段階的に行うが、機械学習応用システムにおける深化プロセスは、人間と機械の協働がある点でユニークであり、機能的な改善に基づくソフトウェアメンテナンスとは大きく異なる。

初期段階の機械学習応用システムは、人間系と機械系がそれぞれ主要な役割とサポート役割を担う。技術が進化し、人間の役割が変化することにつれて、機械系が主要な役割を担い、人間系がサポートを担う次の段階の機械学習応用システムになる。具体的には、自動運転システムの深化プロセスを考えることで、この役割のシフトが理解しやすい。自動運転システムでは、深化プロセスは以下のように定義されている：レベル 1（ドライバーアシスタンス）、レベル 2（部分的な運転自動化）、レベル 3（条件付き運転自動化）、レベル 4（高度な運転自動化）、レベル 5（完全な運転自動化）。一つのレベルから次のレベルへの深化は、機能的な改善を通じたメンテナンスとは根本的に異なり、各レベルで新しいシステムの開発が必要である。自動運転は代表例ではあるが、他の多くの機械学習応用システムでも同様のパターンが観察される。本論文では、特に運用段階における機械学習応用システムの典型的なパターンとして、深化プロセスの 4 つの段階を紹介する。これらの段階には、(1) 可視化、(2) 人間中心 ML 補助、(3) ML 中心人間補助、(4) 自律が含まれる。この深化プロセスは、Porter and Heppelmann (2014) によって提唱された「Smart connected products」として言及されているが、人間系を含んだシステム深化の文脈は考慮されていない。本研究は運用段階にある機械学習応用システムを対象に深化プロセスの観点から分析している。ここでは、運用を担当する人間系と機械学習による出力である機械系の相互作用が発生する。本論文では、機械学習応用システムは機械系と人間系システムを両方含むものとして言及する。例えば、店舗の売上予測に基づいて必要な人員を割り当てる際、人間は機械学習応用システムによって得られた予測と最適化の結果を参照して、実際の人員配置の決定を行う。この機械学習応用システムには、人間系と機械系のモードがあり、これら二つのモードを切り替えることにより、人間・機械協働作業を効果的かつ効率的にタスクを遂行するために活用できる。機械学習応用システムの開発と運用には、経営部門、DX 推進部門、およびそれを利用するユーザー部門など、複数のアクターが関与する。異なるアクター間の情報非対称性により、機械学習応用システムの開発プロセスにおいて様々な課題が生じ、これらの課題は深化プロセスのフェーズによって異なる。



((科学技術振興機構研究開発戦略センター 2017) 人工知能が経営にもたらす「創造」と「破壊」より筆者改変)

図 1-5 従来と異なるソフトウェア開発手法

1. 2. 研究の目的とリサーチ・クエスチョン

企業が競争力を高めるために、顧客への付加価値向上及びデータセントリックな意思決定と業務効率の向上を実現するために DX の取り組みは不可欠である。各種センサーからの情報をインターネットに接続するインターネット・オブ・シングズ (IoT) や、オフィス業務の自動化であるロボティック・プロセス・オートメーション (RPA) により、企業が取り扱うデータ量は飛躍的に増加した。ビッグデータを取り扱うデジタルプラットフォームに機械学習を用いて、予測、推論、最適化などの処理を行うことで DX を支えている。機械学習は従来とは異なるソフトウェア開発手法が必要であり、機械による出力をユーザーがどのように活用し、システムを深化させていくかには多くの困難が存在する。本研究の目的は、企業の DX を分類の上、その進化過程を明らかにし、人間系を含む機械学習応用システムがどのように相互作用し、深化・協働するのかを明らかにすることである。この研究目的を基に、メジャー・リサーチ・クエスチョン (MRQ) とそれを支えるサブシディアリー・リサーチ・クエスチョン (SRQ) を以下のとおり設定する。

MRQ：企業における DX はいかに進化し、その過程で人間と機械学習応用システムはどのように深化・協働するのか？

SRQ1：企業における DX 分類と進化過程は何か？

SRQ2：DX 実行意思は他要素とどのように関係し、いかにして高めることができるか？

SRQ3：機械学習応用システムの深化プロセスの特徴と困難は何か？困難を解消する際に

人間と機械学習応用システムはどのように深化・協働しているのか？

DX は経営要素とデジタル要素の二つに要素を分解することができ、3 章・4 章では経営的な側面から DX を分析し、5 章ではデジタル的な側面を機械学習工学や Human Computer Interaction の観点で分析した。本論文の 3 章では、経営の観点から取り組むべき DX へのアプローチを示し、4 章では DX を推進するうえで重要な DX 実行意思とその他要素について明らかにする。5 章では、機械学習を応用したシステムが持つ固有の特性と新たに出現する困難に焦点を当てる。また、機械学習応用システムの「深化」プロセスを通じて、人間・機械の協働の特性を明らかにし、従来型システム開発とは異なる帰納的ソフトウェア開発特有の深化プロセスにおける人間系と機械系の関係変化を分析する。機械学習応用システムを時間をかけて洗練させる過程を「深化」と定義し、機械学習応用システムの発展に必要な要素とその課題を、人間と機械の関係の観点から考察する。機械学習応用システムの深化は、経営層から現場スタッフまで、様々なアクターの協力と適応が要求される。結果として、本研究は、企業が直面する DX の課題に対処し、機械学習応用システムの深化を通じて持続可能な競争力を構築するための洞察を提供することを目指している。

本研究のチャレンジは、主に 3 点あげられる。

第 1 に、DX および機械学習応用システムの進化・深化を説明するモデルを提示した点である。本モデルは、それぞれのあるべき姿を体系的に示し、組織におけるデジタル技術の効果的な導入と活用のメカニズムを明らかにするものである。第 2 に、機械学習応用システムの深化プロセスにおいて、各ステージで重要となる人間・機械協働の因子を特定した点である。これにより、機械学習応用システムの運用段階で、人間・機械協働がどのように行われるべきか、その鍵となる要素を明確化し、実践的な指針を提供した。第 3 に、DX および機械学習応用システムの進化・深化の概念を統合的に示した点である。これら二つの領域を包括的に捉え考察を行い、組織がデジタル技術を活用して持続的な成長を遂げるための理論的枠組みを提案した。本研究は、DX の進化と人間系を含んだ機械学習応用システムの深化プロセスの提示を行いその特徴と課題を明らかにすることに学術的意義がある。実務家にとっても DX 及び機械学習応用システムが業務内で増加することは必然でありそれぞれのプロセスと特徴を明らかにすることが自社の立ち位置を明確にし、発生する課題を認識できることに実務的意義がある。

1.3. 研究の方法

本論文における研究方法は、まず DX と機械学習応用システムの双方を多角的に分析するために、図 1-6 に示す研究方法で実施した。本研究では、質的なデータに基づく体系

的な分析を行い、企業が直面する DX と機械学習応用システムの課題に対する新たな理論的枠組みを提案する。

第 3 章では、複数の企業における DX の取り組みを分析することで、DX の分類と進化の過程を明らかにした。DX を推進している企業に講演を依頼し、講演情報と質疑応答からデータコレクションを行い、得られたデータに質的分析を行った。

第 4 章では DX 実行意思に関連する因子を先行研究から抽出し、アンケート調査を通じて収集したデータを基に量的分析を行った。本分析により因子間の相関関係を明らかにし、DX 及び機械学習応用システムの深化で必要となる人間・機械協働のための説明変数をステージごとに明らかにした。

第 5 章では、機械学習応用システムの深化プロセスに焦点を当て、人間系を含んだ機械学習応用システムがどのように深化し、人間・機械間で協働していくのかを分析した。半構造化インタビューを通じてデータを収集し、質的分析により機械学習応用システムの深化プロセスの詳細化と人間・機械協働の概念を明らかにした。人間機械協働の詳細化は 4 章で収集したアンケート情報を基に定量分析を行い導き出した。

3 章及び 5 章に共通する研究方法として、テーマティック・アナリシス法(Boyatzis 1998)を用いた質的分析が採用した。これは、インタビューから得られた大量のテキストデータをコーディングし、パターンやテーマを抽出するプロセスであり、結果としてデータに潜む意味や関連性を浮き彫りにする。この分析を通じて理論モデルを構築した。

モデルは 6 章で考察され、DX と人間系を含む機械学習応用システムの関係から発見事項を整理する。本研究は DX と機械学習応用システムが企業内でどのように取り入れられ、どのように進化・深化していくかを探求する。機械学習応用システムの深化における人間の役割とその変化を論じ、人間・機械のより良い協働のための方針を提言する。

本研究は、複雑で多面的な DX や人間系を含んだ機械学習応用システムの現象をより広い視野で捉え、実際のビジネスプラクティスに基づき実証的な結論を導き出した。研究手法として、質的分析に重点を置くことで、数値データだけでは捉えられない組織の内部動態や、被験者の認識、それらが企業のデジタル化にどのように寄与しているかを明らかにした。この研究アプローチにより、DX3 分類の理論モデルと、機械学習応用システムと人間・機械協働の相互作用の理論モデルを提案した。また両理論モデルと関係する因子についても量的分析で導き出した。




図 1-6 本博士論文の研究方法

1. 4. 用語の定義

本論文で使用する用語の定義を以下に示す。

人工知能（AI）

AI（人工知能）は、人間の知能を模倣し、学習・推論・自己修正が可能なシステムやソフトウェアを指す。これは機械学習を含むより広範な技術領域であり、知能的行動の実現を目指す。画像認識、音声認識、自然言語処理、予測、分類、推論を行う。これらは知識獲得のためのオントロジーを含む。本論文では機械学習の上位概念として登場する。

機械学習(Machine learning)

機械学習(Machine learning)は人工知能（AI）を実現するための技術である。従来のIf-then else 型の演繹的なソフトウェア開発とは異なり、データを基にした帰納的開発が特徴。コンピューターサイエンスの分野であり、アルゴリズムを用いてデータからパターンを学習し、予測、分類、推論を行う。機械学習は、入力と出力の関係を理解する「教師あり学習」、データの隠れたパターンを見つけ出す「教師なし学習」、そして試行錯誤を繰り返しながら報酬を最適化する行動を身につける「強化学習」という、三つの主要なカテゴリに分けられる。第一世代のルールベースの機械学習は本論文内の機械学習に含まれない。

機械学習応用システム(Machine learning applied system)

特定の業務遂行を目的に機械学習技術を統合し応用したシステムである。機械学習を単体または複数実装したシステムであり、機械学習は機械学習応用システムに含まれる。

ビッグデータ (Big data)

ビッグデータは非常に大量で複雑なデータセットであり、従来の RDB（リレーショナルデータベース）では処理が困難なものである。広範囲なサプライチェーンにまたがる受発注情報や、顧客の広告接触情報やソーシャルネットワーク上の情報を基にアクター行動分析や予測モデリングなど高度なデータ分析に利用される。非構造化データと構造化データの両方を含む広範囲のデータの集合。

非構造化データ (Unstructured data)

予め定義されたモデルやスキーマがなく、機械による処理が難しいデータ。テキストや画像などが例として挙げられ、自然言語処理や画像認識などの分野で利用される。ビッグデータの一部を形成し、非構造化データの分析に特化した技術が必要。実務上は非構造化データから構造化データをソフトウェアによる処理で生成することも多い。

構造化データ (Structured data)

明確な形式と順序を持ち、データベースなどで容易に管理、処理できるデータ。ERP データ、POS システムなど従来システムからのデータは構造化データである。ビッグデータの一部を形成する。

デジタルプラットフォーム (Digital platform)

ビッグデータを保持し、デジタルサービスやアプリケーション基盤となるシステム基盤。情報保存、配信、運用を支援する基盤技術やサービスの集合である。これにはクラウドコンピューティングサービス、データ管理ツール、API 管理システムなどが含まれる。

機械系 (Machine)

機械学習応用システム内の機械学習モデルにより、予測や推論を自動で行う技術的要素からの出力を指す。機械系はデータからパターンを学習した帰納的な処理に適している。

人間系 (Human)

機械学習応用システムの運用において、機械学習モデルからの出力を基に、人間が意思決定、監視、評価、意味解釈と伝達などを担う、人間の役割や活動を指す。

運用段階にある機械学習応用システム (Operational-stage machine learning systems)

実際の環境でのデプロイメントが完了し、継続的な学習、最適化、性能監視が行われる。この段階では、システムの効果を最大化し、継続的な改善と更新を通じて、ビジネス価値を提供することが目標である。

深化(Exploitation)

深化(Exploitation)の用語は本論文内では主に 5 章で用いられる。本用語は両利きの経営 (O'Reilly and Tushman 2021) の深化 (Exploitation) に由来している。機械学習応用システムがより高度な問題を解決できるように、その性能や能力を向上させることを指す。

進化 (Evolution)

進化(Evolution) の用語は本論文内では主に 3 章で用いられる。単に技術的な進歩や製品の改善を越え、ビジネスモデルの根本的な変革や、顧客に提供する価値の本質的な変化を含んでいる。

深化プロセス(Exploitation process)

システムの深化を実現するための一連の手順や方法論を指す。従来の開発プロセスでは初期的にプロトタイプを構築し、システムをリファインするが、機械学習応用システムを代表とする不確実性の高いソフトウェア開発の場合、現在動いているシステムを基に新たにソフトウェアを再構築することを指す。これにはデータの再評価、モデルの再訓練やチューニング、新たなアルゴリズムの適用などが含まれる。

進化過程(Evolution process)

進化過程は、DX の文脈で、組織やシステムが環境の変化に適応し、技術の進展に合わせて機能やサービスを進化させる継続的なプロセスを指す。これは、自然選択や適応といった生物学的進化の概念に似ており、企業が新たな市場の機会を捉え、競争優位を確立するために不断にイノベーションを追求する動的なプロセスである。

開発プロセス(Development process)

ソフトウェアやシステムの設計、実装、テスト、デプロイメントを通じて製品を構築する一連の手順である。基幹システムや Web システムなど、従来のシステム開発における要求分析、設計、実装、テスト、保守のフェーズを含む。

人間系を含む機械学習応用システム(Machine learning systems including human)

人間の行動、意思決定、フィードバックなどが組み込まれている機械学習応用システムを指す。これには、ユーザーの入力やアクションに基づいてアルゴリズムが学習し、パ

パフォーマンスを改善するシステムが含まれる。例えば、医師が診断を支援するために使用する医療画像分析システムは人間の判断によりシステムが統合的に運用されるため本概念に該当する。

人間系を含む機械学習応用システムの深化(Exploitation of machine learning systems including human)

機械学習応用システムが持つ能力を、人間が理解し活用しきれている状態である。これには、両者のパフォーマンスを最適化するプロセスが必要である。

人間・機械インタラクション(Human machine interaction)

機械は人間のインタラクションに応答し、適応するツールとして扱われる。人間が機械を理解しやすく、効率的に操作できるようにすることが目的であり、ユーザーインターフェース(UI)の設計やユーザーエクスペリエンス(UX)の最適化などが含まれる。

人間・機械協働(Human machine collaboration)

人間と機械が協力して作業を行うプロセス。機械は単なるツールではなく、人間のパートナーとして位置づけられる。機械は独自の「知能」や意思決定能力を持ち、人間の作業を支援し、拡張する。共有作業スペースで人間とロボットが共同で作業を行う工場などが該当する。

人間・機械チームング(Human machine teaming)

人間と機械が単一の協調的なユニットとして機能することを指す。機械はより自律的な役割を担い、人間と同じようにチームのメンバーと見なされる。そのため、新人をチームに受け入れるがごとく、人間と機械の協働を通じて関係性が段階的に進化する。チームとしての集合的な強みを活用し、人間が苦手とする領域を機械が補完することで、より複雑な問題を解決することが目的となる。例えば災害時にドローンや地上のロボットが人間の検索救助隊と協力して救助対象者を探したり、工場の製造プロセスにおいて人間は柔軟性と判断力を、ロボットは疲れ知らずの精度と持続力で協力し合う状態を指す。

1.5. 本論文の構成

本論文では、DX の挑戦に対応する理論的枠組みを提案し、人間系を含む機械学習応用システムの深化及び協働関係を明らかにする。本研究は、テクノロジーの進化とともに変化するビジネス環境において、企業が如何にして DX を進め、人間と機械が協力して効率的かつ効果的なシステムを実現するかを探究する。以下に本博士論文の構成を示す。

第1章 序論

本研究の背景、研究目的とリサーチ・クエスチョン、研究方法、用語の定義、および論文全体の構成を概観する。

第2章 先行研究レビュー

DX、DX の分類、ソフトウェア工学、機械学習工学、プロジェクトマネジメント、人間・機械協働、およびシステム深化に関する先行研究を評価し、本研究の理論的背景とその位置づけを明らかにする。

第3章 デジタルトランスフォーメーションの3分類と進化過程

DX への体系的なアプローチを提案し、その分類と進化過程を事例研究に基づき詳細に探究する。

第4章 DX 実行意思

一次分析では DX を推進するうえで重要となる要素を明らかにする。二次分析では調査対象を広げ、DX 実行意思、DX 分類モデル、機械学習応用システムの深化プロセス、人間・機械協働との相関関係を明らかにする。

第5章 機械学習応用システムの深化プロセス

機械学習応用システムの深化プロセスを明らかにしその過程で生じる新たな課題と困難を展開し、重要な要素となる人間・機械協働の特性を明らかにする。後半人間・機械協働で必要となる要素を深化プロセスのステージごとに明らかにする。本章は学術的には機械学習工学及びヒューマンコンピュータインタラクション (Human computer interaction) に依拠する。

第6章 考察

上記の結果から重要な観点を統合的に考察する。

第7章 結論

本研究のまとめを行い、リサーチ・クエスチョンへの回答と、本研究の学術的貢献と実務的貢献を明らかにし、今後の研究への示唆について総括する。

本論文の主要な研究成果は第3章、第4章、第5章であり、それぞれが研究方法に対して図1-7のように対応している。





図 1-7 論文構成と研究方法の対応関係

2. 先行研究レビュー

本章では、1. 機械学習工学、2. ヒューマン・コンピューターインタラクション、3. デジタルトランスフォーメーションという3つの異なる分野を研究範囲とする。本章1節デジタルトランスフォーメーション及び2節 DX 分類はデジタルトランスフォーメーション領域、3節ソフトウェア工学、4節機械学習工学及び5節機械学習応用システムのプロジェクトマネジメントは機械学習工学領域。6節人間・機械協働は機械学習工学領域とヒューマン・コンピューターインタラクション領域の交差した箇所、7節システム深化はデジタルトランスフォーメーション領域と機械学習工学領域の交差した箇所を主な範囲としている。



(筆者作成)

図 2-1 先行研究の検討範囲

2.1. デジタルトランスフォーメーションに関する先行研究

DX は近年、多くの研究の注目を集めている。企業の保有するデータに焦点を当て、経

営に活用することは、今日では不可欠である。大企業特有のデータに焦点を当てた研究を行い、大企業のブランド力、顧客基盤、業界知識、資産をソフトウェアに統合することによって、製造業が顧客にサービスを提供することが生存の鍵であると論じた (Govindarajan & Immelt 2019)。これらはしばしば大規模な企業変革を伴うが、DX を推進する際の誤解は、大企業がスタートアップの模倣や買収、あるいは大規模なシステムインフラの置き換えなどの決定をしがちであるということであり、これらは必ずしも正しいとは限らない。DX は必ずしも旧来を破壊する必要はなく、データに焦点を当てることで顧客価値を向上可能な、実施可能なことによって形成されるべきである (Furr & Shipilov 2019)。


既存企業のリソースの強みを活かして、新しいプロセスやオペレーションを試すことによってスケールできるビジネスモデルを迅速に発見することが重要である。Mcgrath & Mcmanus (2020) は課題発見主導型 DX を提唱し、これを Discovery-Driven Digital Transformation と名付けた。この意図するところは企業内 DX では変革できることから始めることが重要であり、複数の課題を列挙しパフォーマンスを見える化することが重要とした。DX を推進する際には、システムインフラの活用方法も重要である。Govindarajan & Immelt (2019) は DX のために必要となるビジネスプロセスのデジタル化に向けたいくつかの実用的な方法を提示している。まず初めに社外からデジタル部門の CEO を採用し、ソフトウェアエンジニアを雇用すること。AWS (Amazon Web Service) や GCP (Google Cloud Platform)、Microsoft Azure 等のデジタルプラットフォームを活用すること。シナジーが効く企業の買収を行い、エクイティ調達を加速させることを説いた。Sebastian et al. (2017) は、システムを企業のオペレーショナルエクセレンスを目的とする SoR 領域 (Systems of Record) と、顧客に対する付加価値を提供する SoE 領域 (Systems of Engagement) の 2 つに分けて整理し、ウォーターフォール型開発プロセスを特徴とする SoR 領域、アジャイル型開発プロセスを特徴とする SoE 領域に開発プロセスが異なることを指摘した。

多くの研究において、データの重要性が強調されており、その整理のためにデジタルプラットフォームの活用は不可欠である。ただし、企業内のデータを整理することには、多くのリソースが必要とされ、これらを推進するにはできるところから段階的に進めることが重要である。ただし、DX 推進は顧客を意識する必要がある、顧客との接点を最適化するために従来の SoR 領域とは別の SoE 領域の情報投資が必要である。これを推進するためには従来型のウォーターフォールモデルとは異なる、アジャイル型開発プロセスが必要である。

2.2. デジタルトランスフォーメーション分類に関する先行研究

2004 年、スウェーデンのウメオ大学のエリック・ストルターマン教授がデジタルトラ

ンスフォーメーション (Stolterman and Fors 2004)を提唱した。ただし、一般的に言われる DX までのプロセスである、デジタイゼーション、デジタライゼーション、デジタルトランスフォーメーションの概念は著者がはっきりしていない。Vrana & Singh (2021) が概念を論文として取りまとめている。図 2-2 にデジタイゼーション、デジタライゼーション、デジタルトランスフォーメーションの概念をまとめた。1 点目のデジタイゼーションはアナログデータや物理的データをデジタルデータに置き換えることである。これは例えば、企業間の契約書をスキャンして関係者がオンラインでみれるクラウドストレージに置くことなどを指す。2 点目のデジタライゼーションは企業内のオペレーションをデジタル駆動型プロセスに変革することである。これは社内オペレーションに業務システムを入れて処理に対してタイムスタンプが記述されたものであり、これによりプロセス改善を行うことが可能となる。これは例えば企業間の契約をオンラインで電子署名をすることなどを指す。3 点目のデジタルトランスフォーメーションは顧客価値を伴ったビジネスモデルの変革を指す。例としては、契約書の作成、レビュー、管理をブロックチェーン技術を活用してトレーサビリティを確保しながら、機械学習を活用して契約書のレビューポイントを支援してもらうサービスを社内オペレーション改善の一環で開発しながら、外部への販売も実施するなどの例があげられる。



(筆者作成)

図 2-2 デジタイゼーション、デジタライゼーション、デジタルトランスフォーメーション

多くの研究がドイツの Industry 4.0 や、工場における品質管理・業務効率化、オフィスでの AI 活用など、さまざまなタイプの DX を論じている。DX の分類を議論する際は海外では Business model innovation という言葉もよく用いられる。DX によりビジネスモデル自体が変革するためにこの表現が用いられる。Muller et al. (2018) は、中小製造業を対象に Industry4.0 でビジネスモデルイノベーションを行う際に、Value Creation (価値創造)、Value Offer (価値提供)、Value Capture (価値獲得) と 3 つに分類しビジネスモデルイノベーションにおける価値の分析を行った。価値創造は製造設備、従業員生産

性向上、パートナーとサプライヤーとの協働と3つの観点を示した。価値提供ではプロダクトまたはサービスの形式で価値が届けられることを示した。価値獲得では起業が最終的に経済的なリターンを得るメカニズムとして顧客獲得、顧客とのインタラクション、支払方法の多様化を挙げた。この3つの分類を基に、Ibarra et al. (2018) は、ドイツにおける Industry4.0 を通した DX を時系列で4つの段階に分けた。1つ目は Internal and External Process Optimization であり、2つ目は Customer Interface Improvement、3つ目は New Ecosystems and Value Networks、4つ目は New Business Models: Smart products and services とした。Ismail et al. (2017) は、先行研究を整理し、DX を深化するための6つの視点を提案した。6つの視点とは、1. Individual、2. Company/Institutional、3. Network、4. Industry/Ecosystem、5. Social/Economic、6. Era とした。同論文では、DX における複雑性（縦軸）、DX のインパクト（横軸）として DX におけるアクティビティも整理を行った。最初のステップは社内インテグレーションであり、次のステップはビジネスプロセスやネットワークのリデザインであり、最終的に顧客体験・ビジネスモデルの変革がされると説いた。これらは従来研究の延長ではあるが、IT を活用した業務改善と DX をわけるものである。Saldanha (2019) は DX の進行段階5つのステージに区切り、それぞれの概念を提示している。ステージ1 基礎では、デジタル化に必要なトップからの宣言基本的な構築ブロックが確立されるオーナーシップをもって試行錯誤の重要性を説く。ステージ2 個別対応では、特定のビジネスプロセスに着目しデジタル技術を適用するために権限を付与することが重要とした。ステージ3 部分連携では、異なるプロセスや機能間でのデジタル化の連携を進めデジタル戦略の有用性を説いた。ステージ4 全体連携では、組織全域にわたるデジタルトランスフォーメーションが実現するために組織を再編成し知識の重要性を指摘している。ステージ5 DNA では、デジタルやアジャイルが組織の文化やアイデンティティに根ざし、継続的な変革とイノベーションを常態化させることが重要と説いた。

国内では、Uchihira (2022) は中小企業のスマート工場での DX の取り組みを、守りの DX と攻めの DX に分け、それぞれの特徴と課題を提示した。DX は解釈範囲が広く業務改善を守りの DX として示したものである。

2.3. ソフトウェア工学に関する先行研究

ソフトウェア工学の概念は、1968年に NATO 科学委員会がドイツの Garmisch-Partenkirchen で開催した会議に端を発する(玉井 2008)。この分野は、初期のバッチ処理システムからの進化、対話型、オンライン、リアルタイム、並列処理システムの確立を経て、ソフトウェアの品質と開発者の生産性の向上を目指してきた(大野 1987)。現代において、International Conference on Software Engineering (ICSE)は多くの研究者に

よりこの分野で最も権威ある国際会議として評価されている。特に、機械学習応用システムの登場は、ソフトウェア工学の領域に新たな挑戦をもたらしている。

Royce(1970)は、大規模システム開発のための段階的なアプローチを提唱し、これが後にウォーターフォールモデルとして広く認識されることとなった。しかし、開発プロジェクトの規模が拡大し、複雑性が増す中で、このモデルの限界が明らかになった。2006年頃のセールスフォース・ドットコムではウォーターフォール型を採用して開発をしていたものの、開発進捗が見えなくなり、完成期限が守れず、開発の最後になって変更依頼が集中するといったことが顕在化していた(平鍋・野中 2013)。

これに応える形で、スクラム開発を含むアジャイル開発方法論が出現し、より柔軟で反復的なアプローチを通じて、迅速なフィードバックと継続的な改善を促進する。スクラム開発は、開発プロセスを小さなイテレーションに分割し、継続的な顧客フィードバックと製品の漸進的な改良を特徴とする。このアプローチは、特に曖昧さが高く、要求が変動するプロジェクトにおいて、その柔軟性と迅速な適応能力から高い効果を発揮する。ウォーターフォール開発とアジャイル開発の違いはウォーターフォールが分析、設計、実装、テストを逐次進めていくのに対してアジャイル開発では分析からテストまでの流れを小さなバッチサイズで回すことにある。これによりユーザーは開発プロセス中に随時コーディングがされた成果物、つまり動くものができあがり随時確認をすることができる。ウォーターフォールに比べてユーザーはソフトウェアに対する要求を成果物を見ながら随時入れることができ、要求・仕様が明確でない際は適用しやすい開発手法である。

竹内・野中はスクラム開発は素早く柔軟性を持ってプロダクト開発をするためのものであり、ウォーターフォールが直線的であるのに対してスクラム開発はトライアンドエラーが含まれた統合的なアプローチであると定義した(Nonaka & Takeuchi 1986)。

ソフトウェア工学のフレームワークとしてソフトウェア開発方法論 (Software Development Methodology) が挙げられる。1970年頃は順接、分岐、反復の3制御により処理を記述する構造化プログラミング、1980年頃は各工程で厳密な文章を要求する SSADM (Structured Systems Analysis and Design Method) が定義されている。1990年頃はデータとメソッドをオブジェクトとして定義し、オブジェクトをつなげることで機能を作り出すオブジェクト指向プログラミングや、少人数チームでプロトタイプを作り評価を繰り返す RAD (Rapid Application Development)、前述のスクラム、設計ノウハウをパターンとして記述して再利用しやすくしたデザインパターンなどがソフトウェア開発方法論として定義されている。特に1990年代以降のフレームワークは機械学習応用システムのソフトウェア工学を論じる上では非常に密接に関わる。特に、機械学習の統合によって、新たな方法論やフレームワークが採用されるようになり、これによりソフトウェア工学は効率的で効果的なソフトウェア製品の開発が促進されている。

デザインパターンはオブジェクト指向プログラミングのためのデザインパターン集 (Gamma 1995=1999) で GoF パターンを考案した。ソフトウェア開発で、熟達者が最終的に

到達する課題解決方法をパターンとしてまとめており、それぞれのパターンに名称がついている。これによりその実装方法が明示的になり、その是非を議論することができるようになったわけである。パターンが持つ効果を鷺崎(2011)は規律と創造、再利用、対話の3点としている。規律と創造はソフトウェアに秩序をもたらし構成を定義するのに役立ち、再利用は熟達者の成功した解決方法を新たに課題にあたった際に活用することが可能となる。対話はパターンによりソフトウェア開発の抽象化の手段を与え、効率よく議論する「単語」となることを示している。パターン化する上では、表 2-1 にある各要素が必要となる。

ソフトウェア工学の分野は、その成立以来、著しい進化を遂げてきた。特に機械学習技術の応用により、ソフトウェア開発プロセスは、より柔軟で迅速なアプローチへと変化している。これらの進展は、研究者や開発者に新たな課題を提起すると同時に、未来のソフトウェア工学の展望を大きく広げている。

表 2-1 パターン要素

No.	パターン要素
1	フェーズ(Phase)
2	意図 (Intent)
3	文脈(Context)
4	課題(Problem)
5	解決策(Solution)
6	制約(restrictions)
7	環境(Environment)

(Washizaki et al. 2020 から筆者作成)

2.4. 機械学習工学に関する先行研究

機械学習工学 (Software engineering for machine learning applications(SEMLA)) は、機械学習に基づく帰納的システム開発の方法論 (丸山 2017) を指す。1 章 1 節で述べた通り、機械学習の開発は従来型のルールベースの開発ではなく、学習データを基にモデルを作成し、テストデータで検証をしながら開発が進む。機械学習は教師あり学習 (Supervised Learning)、教師なし学習 (Unsupervised Learning)、強化学習 (Reinforcement Learning) と大きく 3 つの手法がある。これらの手法に従属するアルゴリズムを選定し、データセットを整え、ハイパーパラメータの調整を行うことで学習済みモデルを開発する。帰納的システム開発は上記のプロセスを反復的に行うことで意図す


る結果を取り出すものである。企業が生み出すデータを基に人間が感覚的判断していた事柄を機械学習により推論ができる。データ駆動型経営では不可欠な技術である。ただし、特定の業務遂行を目的に機械学習技術を統合した機械学習応用システムではセキュリティリスク、脆弱性やプライバシーの問題が指摘されている（吉岡 2018）。これらを体系的に整理することが機械学習工学の重要なトピックでもある。国際シンポジウムとしては、セントリオール工科大学が主幹事となっている The Software Engineering for Machine Learning Applications (SEMLA) international symposium が著名である。ここでは、アーキテクチャ・ソフトウェア設計、モデル/データの検証、ユーザーエクスペリエンスの評価と調整、プライバシー、安全性、セキュリティや論理的懸念について取り扱っている。

企業での機械学習の活用の視点から、バリューチェーン全体での最適化を実現するためには、ビッグデータの取得、前処理、そして AI モデリングが必要であり、この分野はソフトウェアエンジニアリングの観点から分析されてきた。Fayyad et al. (1996) は、KDD (knowledge discovery in databases) を提唱し、データベースから知識を発見することを提案した。これはデータ中心の、反復的かつ対話的なプロセスであり、機械学習応用システムのためのソフトウェアエンジニアリングの基礎となる。データマイニング、機械学習、知識獲得、データ可視化の観点からデータからの知識獲得は重要である。知識は、データ内に存在するパターンを識別し、解釈し、評価することによって獲得される。しかし、データに人間系のオペレーションが含まれる場合、データ損失やデータからのパターン解釈に問題が生じることがある。これは人間系を含む機械学習応用システムにおいて共通の問題である。

Wirth and Hipp (2000) は「確かな方法論と効果的なプロジェクト管理」がデータマイニングには必要であると述べ、プロジェクト管理と文書標準化の概念を追加した。データマイニングのための CRISP-DM (CRoss Industry Standard Process for Data Mining) モデルは、ビジネス理解とデータ理解によって特徴づけられる。データサイエンティストは、データの品質とドキュメントを精査することによってプロジェクトの目的を理解しなければならず、技術プロセスであるデータマイニングにプロジェクト管理の概念を導入する新しさがある。

機械学習応用システムは、関連するデータ収集および検証プロセスだけでなく、データインフラの固有の複雑さ (Sculley et al. 2015) も存在する。品質を確保するため、AI モデルはブラックボックスシステムである (Riccio 2020) ため、実験的アプローチは様々なプロジェクトで頻繁に使用されている。Watanabe (2019) は機械学習応用システムの開発プロセスに関する体系的な文献レビューを実施した。モデルトレーニング、評価、機械学習プロセス、プロジェクトに基づく問題など、多くの論文が出版されている。例えば、Amershi et al. (2019) は、複数のマイクロソフト社内機械学習プロジェクトの分析から、モデル要求～モデルモニタリングまで機械学習ワークフローを The nine stages of the machine learning workflow として 9 つのステージ(図 2-3)に整理した (Amershi et

al. 2019)。9つのステージは 1. Model Requirements, 2. Data collection, 3. Data Cleaning, 4. Data labelling, 5. Feature engineering, 6. Model Training, 7. Model Evaluation, 8. Model Deployment, 9. Model Monitoring である。9つのステージは線形いくつかのフィードバックループが含まれることを示している。



(Amershi et al. 2019 から筆者作成)

図 2-3 機械学習ワークフローの9つの段階 (The nine stages of the machine learning workflow)

Microsoft や Google などの企業はデータインフラを提供するだけでなく、機械学習応用システムを作成するための独自のプロセスモデルも示している。(Microsoft: What is the Team Data Science Process?; Google: Machine learning workflow)

ここでは、機械学習応用システムを開発するためのフローが定義されているが、機械学習応用システムが漸進的に更新されるプロセスは定義されていない。また、一連の研究は人間・機械協働作業の概念を記述していない (Fayyad et al. 1996; Wirth and Hipp 2000; Amershi et al. 2019)。近年、機械学習応用システムにおける倫理、品質保証、およびビジネスの考慮事項に関する数多くの議論が焦点となっている。機械学習応用システムは時々、倫理的な観点から問題のある出力を生成懸念事項となっている。ソフトウェアに機械学習コンポーネントを統合することがますます普及しているため、公平性や説明可能性を含む機械学習応用システムの品質要件について新しい視点が求められている。倫理的な問題に対処するには、異なる分野のエンジニアや科学者間の適切なコミュニケーションが必要であり、エンジニアリングや処理の問題に対処だけでなく、ドキュメントが重要であると提案されている (Nahar et al. 2022)。

実務上、技術的な負債の存在する機械学習応用システムを採用することがある。これは、技術的負債を解消せずに最適でないソリューションを選択したこととなり、将来的に品質保証上の問題を引き起こすこととなる。この技術的負債は機械学習応用システムの固有の不確実性ともいえ、修正のために将来のコストを増加させる可能性がある。この問題を深く理解するため、特定のパターンに基づき分類された研究がある。Sculley et al. (2015) は、これらをアンチパターンにまとめて、システム設計のリスク要因を整理し

た。Washizaki et al. (2022)は、機械学習応用システムの設計プロセスにおける 15 のデザインパターンを提案した (図 2-4)。Topology に 6 種類、Programming に 4 種類、Model Operation に 5 種類のパターンを提示している。これらのアプローチは、機械学習応用システム設計のベストプラクティスを使用して、機械学習応用システム固有の高い不確実性を工学的な観点から軽減しようとする試みである。

ビジネスの観点からは、データ集約し、機械学習の活用を行うことは様々な業界でいられている。例えば、医療、製造、教育、財務モデリング、警察、マーケティングなど、さまざまな分野で使用されている (Jordan and Mitchell 2015)。これらは、ビジネスプロセスの最適化、製品開発、サービス開発を含む企業のバリューチェーンのさまざまな側面に貢献している (Agrawal et al. 2018)。機械学習応用システムの開発と活用には、多くの専門家とステークホルダー間の協力が不可欠であり、新しいビジネスプロセスやチームにつながる (Nahar et al. 2022)。

ID	Pattern name	Quality
Category: Topology		
P_1	Different Workloads in Different Computing Environments [4], [5]	E, M
P_2	Distinguish Business Logic from ML Models [6], [7]	M
P_3	ML Gateway Routing Architecture [6]	C, M
P_4	Microservice Architecture [7]–[9]	C, M, P
P_5	Lambda Architecture [10]–[12]	E, R
P_6	Kappa Architecture [13]	E, R
Category: Programming		
P_7	Data Lake [7], [10], [14], [15]	E, C, M
P_8	Separation of Concerns and Modularization of ML Components [16]	M
P_9	Encapsulate ML models within Rule-based Safeguards [5], [17]	R, S
P_{10}	Discard PoC Code [18]	M
Category: Model operation		
P_{11}	Parameter-Server Abstraction [18]	E, R
P_{12}	Data flows up, Model flow down [5], [19]	E, Mr, Pa
P_{13}	Secure Aggregation [19]	S, Mr, Pa
P_{14}	Deployable Canary Model [20]	R, Me
P_{15}	ML Versioning [4], [7], [18], [21]	M, Mr, Pa

((Washizaki et al. 2020) Practitioners' insights on machine-learning software engineering design patterns: A preliminary study より引用)

図 2-4 ML パターン名

データマイニングとそのビジネスへの適用に関する既存の研究を概観し、Knowledge Discovery in Databases (KDD) と Crisp-DM という二つの主要なプロセスモデルが、異なる目的を持ちつつも、プロセスの構造化という共通のアプローチを採用している。この双方の方法論は、データマイニングにおけるプロセス指向の重要性を強調している。これらは機械学習応用システムを構築する際のデータ処理やデータモデリング、データサイエンスにおける指針となっている。Amershi et al. による「The nine stages of the machine

learning workflow」は、機械学習応用システムの開発におけるプロセスモデルの重要性を再確認するものである。特に、データラベリングやモデルの継続的モニタリングといった、機械学習特有の処理を取り込んだこのモデルは、従来のプロセスモデルには見られない、機械学習の実践における具体的な課題に対処するための体系的なフレームワークを新たに提案している。

また、Washizaki et al. (2022)による機械学習応用システムの開発と運用に関するデザインパターンの提案は、従来の機械学習プロセスのみでなく、機械学習応用システムとして必要な知識体系をまとめたものであり、この分野における研究の進展を示している。これらのパターンは、機械学習応用システムの設計と実装における一般的な問題に対する解決策として機能し、開発プロセスの効率化と品質の向上に貢献する。

データマイニングと機械学習応用システムに関するプロセスモデルとパターンの進化を追ってきた。これらのモデルとパターンは、データ駆動型の意思決定とイノベーションを促進し、機械学習応用システムの発展に不可欠なものである。

2.5. 機械学習応用システムのプロジェクトマネジメントに関する先行研究

プロジェクトは、有期性と独自性を特徴とする非定常業務の遂行としてそれぞれ定義される。プロジェクトマネジメントは、プロジェクトで定義されている特定の目標を達成するために一時的なチームを組織し、専門知識を活用してプロジェクトを効率的かつ効果的に遂行し、確実な成果を得る実践的能力の適用とされる。管理の対象としては、予算、スケジュール、資源、スコープがある。プロジェクトマネジメントの知識体系は、PMI (Project Management Institute) によってPMBOK (Project Management Body of Knowledge) として体系化されており、これは2021年に第7版が出版されたものが最新版で、プロジェクトの12の原理原則と、プロジェクト管理のための8つのパフォーマンスドメインから構成される。第6版まではウォーターフォール型開発を対象としていたが、第7版からアジャイル開発やプログラムマネジメントの概念も取り扱うようになった。


一方で、日本プロジェクトマネジメント協会は、プログラムとプロジェクトマネジメントを統合的に扱うP2Mを提唱し、これは複数のプロジェクトを組み合わせる複雑で大きな価値創造命題を達成するための統合的活動と定義している。P2Mの最新版は2014年に出版された第3版である。PMBOKとP2Mは、それぞれ異なるアプローチを提供し、プロジェクトとプログラムの成功をサポートするための具体的な手法とフレームワークを提供している。

Amershi et al. (2019)によると、機械学習応用システムの開発において、熟達者とビギナーは異なる課題を抱えている。データコレクションは共通の大きな問題であるが、ビギナーは教育や大規模システムの適用を、熟達者は運用面の課題をそれぞれ挙げている。一方、田中・久保(2018)は、P2M理論を適用し、データコレクションと精度向上のための

現場との調整の重要性を訴えている。小西・本村(2017)は、産総研の28件のAIプロジェクトから、プロジェクト失敗の原因として担当者の異動や意識共有不足、データ収集の高コストを挙げている。プロジェクト成功の鍵は、目的に合った質の高いデータを低コストで収集し、その活動を持続可能にすることにあると示されている。これは、実用可能な領域を設定し、そこでテスト運用を回しながら徐々にスケールを大きくするスパイラル型の過程を取ることが多く、データ収集の工夫やスパイラル過程を通じたプロジェクト循環の重要性を示している。これらの研究は、機械学習応用システムの開発における技術的課題とともに、人と組織との協力の必要性を強調している。特に、データの質を高め、業務自動化におけるAIの活用を成功させるためには、多くの部署の調整や人間の協力が不可欠である。また、機械と人間の共生や社会システムとの融合も重要な考慮点となっている。江間・秋谷は、“運転・育児・防災活動、どこまで機械に任せるか”において、“個別場面において人間の仕事が完全に機械に置き換わるのではなく、どのように機械と人間の仕事を切り分け、タスク単位でどこまで何を機械に任せるのかを、創造的に考えていく作業が求められる”と述べている(江間ほか 2016)。これらのことから人間系を考慮した機械学習応用システムのプロジェクトマネジメントが不可欠である。

2.6. 人間・機械協働に関する先行研究

Pan (2016)は、人間と機械学習応用システムのハイブリッド知識が機械学習に新たな可能性を開くと述べている。機械学習応用システムと人間は双方向的であり、双方向性を通して機械学習応用システムは人間の選択の好みを学習し、パフォーマンス向上のために動的に適応すると Bosch and Bronkhorst (2018)は主張した。彼は人間と機械学習応用システムの意思決定における協働(図 2-5)で、当初は機械学習応用システムから人間に一方的に情報が渡されそれもブラックボックスであるとしたが、説明性が担保されることで人間と機械学習応用システムの双方向性が認められるとした。協働のためには観測変数を基に最適化され、何らかの意思(Theory of mind)を双方が持つことにより協働が成り立つとした。



(Bosch and Bronkhorst 2018 から筆者作成)

図 2-5 人間と AI の協働意思決定のレベル (Levels of human-AI collaborative decision making)

機械学習応用システムと人間との協力は不可欠であり、両者は効果的な協力スキルを持たなければならない(Matthew and Alonso 2019)。しかし、ビジネスにおける人間と AI の協働において、人間と機械のハイブリッド活動がしばしば見過ごされがちである。Daugherty and Wilson(2018)は人間と機械学習応用システムの協働において人間だけの活動とマシンだけの活動の間のミドルをミッシングミドル(図 2-6)として位置付けてこの間を埋めるのが人間とマシンのハイブリッド活動であるとした。ここではマシンの補助を行う人間と人間の活動を補助する AI に分けられるとした。これは人間系と機械系で得意な処理が違い、その間を埋めるうえでの処理に着目したものである。

主 導	共 感	創 造	判 断	訓 練	説 明	維 持	増 幅	相 互 作 用	具 現 化	ト ラン ザ ク シ ョ ン	反 復	予 測	適 応
人間にしか できない活動				人間が機械を 補完する			AIによる 人の能力拡大			機械にしか できない活動			
				人間と機械の ハブリッド活動									

(Daugherty and Wilson 2018 から筆者作成)

図 2-6 ミッシングミドル

人間と機械の協働の関係性に着目したのが Babic et al. (2021)である。彼は、機械学習応用システムが現場で受け入れられるための 4 つのステップ、すなわちアシスタントからモニター、コーチ、チームメイトへという提案をしている。これは機械を単に人間にとって都合の良いツールとしてではなく新人を扱うように人が機会を受け入れる際のステップを明示した。これは人間・機械チーミング(Human machine teaming)の概念でもある。機械学習応用システムと人間のチーミングに必須なインタラクションとデザインのガイドラインは Amershi et al. (2019)や Yang et al. (2020)によって開発されている。ただし、人間と機械学習応用システムのチーミングに関するガイドラインは以前に示されていたが、モデルとしては定式化されていない。

人間・コンピューターインタラクション (Human computer interaction) は人間とコンピュータの間のインタラクションを研究する分野でありユーザーがコンピュータを効率的に使えるようにするためにユーザーインターフェースやユーザーエクスペリエンスの最適化をすることを指す。人間・コンピューターインタラクションの一部が人間・機械インタラクション (Human machine interaction)であり、機械が人間に適応する方法に焦点を当てている。この分野は人間に焦点を当て、エージェント間の相互作用や認知科学、インターフェースを論じている。人間・機械協働(Human machine collaboration)は、機械学習応用システムを単なるツールとしてではなく、人間がそれらと協力する概念である。ここでは、人間と機械学習応用システムの強みと弱みが相補的である点が大きな特徴である。人間・機械チーミング(Human machine teaming)は、機械が人間によって個人として認識

され、人間と機械学習応用システムの統合に焦点を当てている。この分野では、人間と機械が統一されたチームとして共に作業する。

Saenz et al. (2020)は、リスクレベルとプロセスの開示度に基づいて、人間と AI の操作を説明している。リスクが低くプロセスがクローズされた領域では、機械学習応用システムは主に機械モードで運用される。リスクが高くプロセスがクローズされている場所では、人間が監視し、機械学習応用システムがほとんどの処理タスクを実行する。リスクが低くプロセスがオープンな場合、人間は機械学習応用システムをコーチしながら、機械と人間モードの間で責任を交互に行う。リスクが高くプロセスがオープンな場所では、人間と機械システムが相互作用しながら人間が最終的な権限を持つ。意思決定の文脈では、機械学習アルゴリズムだけでなく、人間の専門知識と直感を活用することが重要である。

人間・機械インタラクション (Human machine interaction)、人間・機械協働 (Human machine collaboration)、人間・機械チームング (Human machine teaming) を表 2-2 にまとめた。

表 2-2 人間・コンピューターインタラクション、人間・機械インタラクション、人間・機械協働、人間・機械チームング

No.	Category	Content
1	人間・コンピューターインタラクション (Human computer interaction)	人間とコンピュータの間のインタラクションを研究する分野でありユーザーがコンピュータを効率的に使えるようにするためにユーザーインターフェースやユーザーエクスペリエンスの最適化をすることを指す
2	人間・機械インタラクション (Human machine interaction)	機械は人間のインタラクションに応答し、適応するツールとして扱われる。人間が機械を理解しやすく、効率的に操作できるようにすることが目的であり、ユーザーインターフェース(UI)の設計やユーザーエクスペリエンス(UX)の最適化などが含まれる。
3	人間・機械協働 (Human machine collaboration)	人間と機械が協力して作業を行うプロセス。機械は単なるツールではなく、人間のパートナーとして位置づけられる。機械は独自の「知能」や意思決定能力を持ち、人間の作業を支援し、拡張する。共有作業スペースで人間とロボットが共同で作業を行う工場などが該当する。
4	人間・機械チームング (Human machine teaming)	人間と機械が単一の協調的なユニットとして機能することを指す。機械はより自律的な役割を担い、人間と同じようにチームのメンバーと見なされる。そのため、新人をチームに受け入れるがごとく、人間と機械の協働を通じて関係性が段階的に進化する。チームとしての集合的な強みを活用し、人間が苦手とする領域を機械が補

完することで、より複雑な問題を解決することが目的となる。例えば災害時にドローンや地上のロボットが人間の検索救助隊と協力して救助対象者を探したり、工場の製造プロセスにおいて人間は柔軟性と判断力を、ロボットは精度と持続力で協力し合う状態を指す。

(筆者作成)

2.7. システム深化に関する先行研究

情報技術を基軸としたトレンドは3つの波がある。1960年代から始まり、企業内ITの導入による生産性の飛躍的向上を第一波として捉え、続く1980年代と1990年代にはインターネット技術の普及により企業間連携が可能となり、グローバルなサプライチェーンの構築を第二波と位置付けた。そして、近年の第三波は、情報技術がプロダクト自体に統合され、センサーやプロセッサ、ソフトウェアが一体となった「コネクテッドプロダクト」を通じて、新たな付加価値の創出が可能となっている。この第3のコネクテッドプロダクトの深化プロセスをPorter and Heppelmann(2014)はCapabilities of Smart Connected Product (スマートコネクテッドプロダクトの深化プロセス) (図 2-7) としてまとめた。この枠組みは、プロダクトが提供する機能を監視 (Monitoring)、制御 (Control)、最適化 (Optimization)、自律 (Autonomy) の4つに分類し、それぞれの機能が深化することで、プロダクトの価値を高めていくかを示している。例えば、医療用機器が患者の血糖値を監視し、異常値を検知した際には通知を出す監視機能や、スマート電球が不審者の動きに反応して色を変える制御機能など、多岐にわたるアプリケーションが存在する。

④自律化 Autonomy			
③最適化 Optimization			
②制御 Control			
①監視 Monitoring			
センサーと外部データソースによる、 ・製品の状態 ・外部環境 ・製品の操作と使用 の包括的な監視	製品やクラウドに埋め込まれたソフトウェアによる ・商品機能の制御 ・顧客体験のパーソナライズが可能	監視と制御の機能は、製品の運用と利用において、 ・製品の性能向上 ・予測診断、サービス、修理のための最適化が可能	監視・制御・最適化を組み合わせることにより ・商品の自律的な運用 ・他製品やシステムとの自動連携 ・自律的な製品強化 ・パーソナライゼーション ・自己診断とサービスが可能

(Porter and Heppelmann 2014 から筆者作成)

図 2-7 スマートコネクテッドプロダクトの深化プロセス (Capabilities of Smart Connected Products)

1つ目は監視（Monitoring）である。監視ではセンサーや外部データソースとの比較によりプロダクトの状況を可視化、監視をすることでアラートをあげることを指す。2つ目は制御（Control）である。ソフトウェアがプロダクトの監視をもとに閾値に達した際は機能を制御することを指す。例えば不審者が家の前を通ったときにスマート電球が赤く光るなどの制御である。3つ目は最適化（Optimization）である。監視と制御の機能によりプロダクトのパフォーマンスを最大化する制御が自動で行われることを言う。風力発電機のブレードを風の状態を監視しながら発電効率の最大化を図るなどがあげられる。4つ目は自律（Autonomy）である。監視、制御、最適化を組み合わせることで自律的なプロダクトの運用が可能となる。iRobot の Roomba は部屋の状況を自動的認識して自動で掃除を完遂する。自律は他のプロダクトやシステムと連携し付加価値を高めることが可能である。例としてスマートメーターを活用したスマートグリッドを挙げている。（表 2-3）

表 2-3 スマートコネクテッドプロダクトの 4 機能と事例

フェーズ	内容	事例
監視 (Monitoring)	センサーや外部データソースとの比較によりプロダクトの状況を可視化、監視をすることでアラートをあげる	センサーを皮膚の下に埋め込み、血糖値が閾値以下の際通知をする医療用機器(Medtronic)
制御 (Control)	ソフトウェアがプロダクトの監視をもとに閾値に達した際は機能を制御する	不審者が家の前を通ったときにスマート電球が赤く光る (Philips Lighting)
最適化 (Optimization)	監視と制御の機能によりプロダクトのパフォーマンスを最大化する制御が自動で行われること	風力発電機のブレードを風の状態を監視しながら発電効率の最大化を図る（社名無）
自律 (Autonomy)	監視、制御、最適化を組み合わせることで自律的なプロダクトの運用	部屋の状況を自動的認識して自動で掃除（iRobot Roomba）

((Porter and Heppelmann 2014) How smart, connected products are transforming competition から筆者作成)

Iansiti and Lakhani (2020)は、DX の成功と失敗のケースを調査し、成功した企業は大量のデータを活用して AI を導入する重要性を指摘し、企業が AI を取り入れるプロセスを AI Factory という概念で提案した。

Frank and Ayala (2019)は Industry4.0 の技術を Front-end Technologies と Base Technologies に分けた。Front-end Technologies は Smart Supply Chain, Smart Working、Smart Manufacturing、Smart Product の 4 つに分けられるとした。Base technologies は IoT、Cloud、Big data、Analytics の 4 つに分類した。この概念を成熟度モデルとして 3 段階に提示した。1 つ目が垂直統合やエネルギーモニタリング、トレ

ーサビリティの確保といった Stage1 でありこれにはクラウドや IoT が重要であるとした。2 つ目が自動化やバーチャライゼーションといった Stage2 でありこれにはビッグデータ活用や AI が重要であるとした。3 つ目が自由度 (Flexibilization) の Stage3 であり、これには自律的な Smart Product や拡張現実の実現のために分析基盤がより重要度を占めるとした。Sjödín et al. (2021) はビジネスモデルイノベーションのために AI 能力がどう影響するかを質的研究により調査した。ここではデータパイプライン能力、AI 市民化能力、アルゴリズム開発能力といった AI を扱う能力を基に、データ駆動型オペレーションのや顧客とのアジャイルでの共創、スケーラブルなエコシステムが重要であるとした。Haaker et al. (2021) は IoT ビジネスモデルをサービタイゼーションレベルとデジタルレベルを掛け合わせて、Convergence、Technology-push、Demand-pull、Low added value と 4 つの Region に分類した彼らはデジタル化とサービタイゼーションが革新的なビジネスモデルの開発に不可欠であると述べた。これらの論文は経営学の視点から深化を議論しており、デジタル変革、Industry4.0、AI 駆動ビジネスモデル、IoT ビジネスモデルなど、さまざまなビジネスモデルが関与している。

成熟度モデルは、深化の概念を示唆しているものの、機械学習の深化プロセスとは異質のものである。成熟度モデルが必要案技術に注目しているのに対し、機械学習の深化プロセスは、機械学習応用システムおよび機械と人間との協働がどう段階的に深化するかに焦点を合わせている。先行研究では、人間と機械、機械学習応用システムが段階的にアップグレードする過程で、人間と機械の協働作業を伴う深化概念が十分には考察されていない。

2.8. 先行研究の課題と本研究の位置づけ

先行研究では主に 3 点を取り上げた。1 点目は本章 1 節、2 節の DX、2 点目は本章 3 節、4 節、5 節の機械学習工学及びプロジェクトマネジメント、3 点目は本章 6 節、7 節のシステム深化と人間・機械協働についてである。先行研究の課題と本研究の位置づけを図 2-8 にまとめた。

1 点目の DX は、企業がテクノロジーを活用して経営戦略やビジネスモデルを変革する過程である。この分野の研究は、データ活用、新しいビジネスプロセスの確立、顧客価値の向上などに焦点を当てている。例えば、Govindarajan & Immelt (2019) は、大企業が DX を通じて新たな顧客サービスを提供する方法について研究した。McGrath & McManus (2020) は、DX において、発見主導型のアプローチの重要性を強調した。Sebastian et al. (2017) は、企業のシステムの運用効率化と顧客エンゲージメント向上の二つの側面に分類し、それぞれに対するアプローチの違いを指摘した。しかしながら、これらの研究は企業の DX を推進する具体的な方法論や戦略に焦点を当てているものの、企業のデータに着目して経営学的見地から DX の分類やフレームワークの提案には十分な注意が払われていな

い。この不足を補うために、DX の進行過程を体系的に捉え、その各段階の特徴明確に定義することが必要である。

2 点目は機械学習工学の観点であり、先行研究はフィードバックループやアジャイル開発を含んだ理想的なプロセスを提示している (Fayyad et al. 1996; Amershi et al. 2019)。機械学習応用システムが発展的にバージョンアップされていく「深化」の概念を取り扱っている (Porter & Heppelmann 2014) が、人間系を含んだ機械学習応用システムが発展的に業務の中でバージョンアップされていく「人間系を含んだ深化」の概念は取り扱われていない。機械学習応用システムのプロジェクトマネジメントの観点では理想的なプロジェクトマネジメントの提案 (田中・久保 2018) や機械学習応用システムが会社内で扱われる際のサイクルの分析 (小西・本村 2017)、社会実装の課題分析 (本村 2018) が研究されている。いずれもプロジェクトマネジメントにおける機械学習応用システムを会社・社会の視点で論述しているものの、ユーザーである人間と機械学習応用システムを分析対象として「深化プロセスのパターン」を論じている論文は管見の限り見当たらない。

3 点目はシステム深化と人間・機械協働である。人間と機械の協働に関する研究は、人間と機械の働き方を新たに提示するものであり、システム深化に伴う人間・機械協働は研究余地がある。Pan (2016) は、人間と機械学習応用システム間のハイブリッド知識が機械学習に新たな可能性をもたらすと指摘している。この双方向性を通じて、機械学習応用システムは人間の判断を学習し、動的に適応する能力を持つ。一方、Bosch and Bronkhorst (2018) は、説明可能性が確保されることで、人間と機械の双方向性が実現すると主張している。Daugherty and Wilson (2018) は、人間と機械の協働における中間領域、すなわちミッシングミドルに着目し、その埋め方を探求している。これらの研究は、機械学習応用システムの深化プロセスでの人間と機械間の協力的な関係性の構築が、十分に探究されていない。特に、人間・機械協働のプロセスにおいて、双方の強みを活かし合い、相互に補完し合う形での深化が求められている。この文脈で、機械学習応用システムの深化は、単に技術的な側面だけでなく、人間との協働的な関係性をどのように築き、深めていくかが重要な課題となっている。この研究領域においては、機械学習応用システムの深化と共に、人間とのインタラクションや協力形態も進化し、より複雑な問題解決に向けての連携が模索されるべきである。人間と機械が共に成長し、互いに学び合いながら新たな価値を創出していくプロセスの理解が、この分野の将来を形作る鍵となる。

本研究の目的は、機械学習応用システムの深化プロセスおよび人間と機械の協働作業の枠組みを明確化することにある。これらは、人間と機械の協働を含む機械学習応用システムの活用において重要な意義を持ち、これまでの文献では十分に論じられてこなかった。本論文では、事例分析を通じて、深化プロセス及び人間・機械協働の管理方法を明らかにすることを試みる。これらのことから、本研究は人間系を含んだ機械学習応用システムが発展的に業務の中でバージョンアップされていく「人間系を含んだ深化」の概念を取り扱うことに研究意義がある。




図 2-8 先行研究の課題と本研究の位置づけ

3. デジタルトランスフォーメーション 3 分類と進化過程

本章では MRQ の DX の進化と人間と機械学習応用システムの深化と協働の構成要素である、DX の進化について説明する。近年競争環境は劇的に変化しており、企業はオペレーション上で発生するデータに価値を見出す動きを強めてきた。この文脈においてデータに着目してどのように企業が DX をしてきたかを明らかにする。この研究の目的は DX を実現してきた企業がどのように自社の DX を推進してきたかを 8 つの事例から DX を推進するうえで 3 つの分類があることを提案する。

3 章 1 節では DX と機械学習応用システムの関係について、3 章 2 節では研究目的と事例研究を採用した理由、研究方法を示す。3 章 3 節では研究方法とテーマティック・アナリシス法による分析結果を示す。3 章 4 節では DX の分類を示しそれぞれの内容と講演内容で代表的なコメントを記す。3 章 5 節では DX の分類ごとの特徴を記す。3 章 6 節では事例ごとの DX の分類をどのように変遷したかの進化過程を示す。

3.1. DX と機械学習応用システム

Appio et al. (2021)は DX の包括的なレビュー論文で複数の論文からキーワード形態素解析し共起分析を行った。Digital transformation の周りには Digital Platforms、Digital Innovation、IoT、Open innovation、Digital entrepreneurship、Innovation Management、Business model innovation といったキーワードの出現量が多いことがわかる。これらのキーワードと共起が近いキーワードをそれぞれ表 3-1 にまとめ、これらにラベルを付け分類を行った。

表 3-1 DX のキーワードと分類

No.	キーワード	共起キーワード	ラベル
1	Digital Platforms	Digital Platforms	デジタル技術要素
2	Digital Platforms	Appropriability mechanisms	デジタル技術要素
3	Digital Platforms	Ecosystem	経営要素
4	Digital Platforms	Bundling	デジタル技術要素
5	Digital Innovation	Digital Innovation	デジタル技術要素
6	Digital Innovation	Architectural practice	デジタル技術要素
7	Digital Innovation	Competing concerns	デジタル技術要素
8	Digital Innovation	Fundamental and powerful concepts(fpc)	デジタル技術要素
9	IoT	IoT	デジタル技術要素
10	IoT	Artificial intelligence	デジタル技術要素
11	IoT	Algorithmic bias	デジタル技術要素
12	Open innovation	Open innovation	経営要素
13	Open innovation	Crowd funding	経営要素
14	Open innovation	Sustainability	経営要素
15	Open innovation	Company community relationship	経営要素
16	Digital entrepreneurship	Digital entrepreneurship	経営要素
17	Digital entrepreneurship	Bigdata analysis	デジタル技術要素
18	Digital entrepreneurship	Social media	デジタル技術要素
19	Innovation management	Innovation management	経営要素
20	Innovation management	Change management	経営要素
21	Digital transformation	Processes	経営要素
22	Digital transformation	Product service systems	経営要素
23	Digital transformation	Exploration and exploitation	経営要素
24	Business model innovation	Business model innovation	経営要素
25	Business model innovation	Customer development	経営要素
26	Business model innovation	Service innovation	経営要素
27	Business model innovation	Microfundation	経営要素

(Appio et al. 2021 から筆者作成)

これらが意図することは DX にあたって多くのキーワードが存在するが多くがデジタル技術または経営に関わる用語である。DX には経営と、デジタル技術の 2 面があり、その両面が DX における分析対象である。多くの先行研究がそれぞれを論じているが DX にあたって経営面及びデジタル技術面を分けてそれぞれの変革プロセスを書き分けているものは管見の限り見当たらない。

経営側面では 2 章 2 節で論じた Saldana(2019)は経営トップが戦略のオーナーシップを感じており、デジタル技術が特に破壊をもたらす分野を戦略的に選ぶことが重要である

とした。経営陣は企業の長期ビジョンと目標を定義し、これを実現するための戦略を策定することが重要であり、そのために機械学習応用システムを導入することは、意思決定をデータ駆動でサポートし、より精度の高い決定が可能となる。ただし、経営的な視点がなければどのようなデータをどう活用すべきか、またそれが企業のどのような戦略に寄与するのかを正確に判断することができない。企業がどのようにデータと向き合い DX を推進してきたかを分類したいと考えた。

デジタル技術の側面では企業の競争優位の確立のために大量の企業が生み出すデータから有益な洞察を引き出すことが重要であり、これらを活用するためには機械学習技術が必要である。2 章 7 節で論じた Iansiti and Lakhani (2020) のいう AI Factory もこの考え方に即している。例えば顧客行動を予測することでパーソナライズされた顧客体験を提供することで顧客価値を向上させるなどである。これにはデータの収集、データ基盤構築、AI アルゴリズムの選定、改善の断続的なサイクルが必要である。これらをどのようにステージを分けて進化するかを本論文では研究テーマとしている。

3.2. 事例研究の目的

DX の先行研究のギャップを明確にすることは、学術および実務の両分野において重要である。本節では、先行研究から選出した研究事例を紹介し、それぞれの特徴と限界を検討することで、DX 研究における今後の方向性を提言する。DX に至る分類でもっとも知られているモデルは、図 2-1 に示した、デジタイゼーション、デジタライゼーション、デジタルトランスフォーメーションである。この概念ではデジタイゼーションはアナログデータをデジタル化せよという点で、デジタル的な観点では意味のある示唆となっている。ただし、経営的視点では誰に対してどのデータをデジタル化するかが重要であるといえるがそれには十分には答えられていない。ここが本研究の出発点となった。

2 章 1 節及び 2 節で述べたように現行の DX 研究では、特定の産業セクターや企業にフォーカスした実践的な示唆はあるものの、DX の概念がどのように適用され、進化するかという視点が不足している。特に、ビッグデータを中心に付加価値を生成する DX の推進では、社外アクターやエコシステムとの連携にまで目を向ける必要がある。本研究ではこれらのギャップを埋めることを目的とし、データの視点や社外アクターとの連携を重視した新たな DX 分類モデルの提案を目指す。本研究はビッグデータを基にした付加価値、DX を取り巻くマルチアクターの分析や時系列で進化概念を取り扱う必要があり、その複雑な事象を解き明かすために事例分析を適応する。

3.3. 研究方法

本研究では、DX の分類及びその進化過程を明確にすること目的としている。本研究は 3 ステップで進め、手順は図 3-1 にある通りである。1 ステップ目に対象者に対して講演と質疑応答を通じてデータコレクションを行った。2 ステップ目にテーマティック・アナリシス法(Boyatzis 1998)により質的分析を行った。3 点目にモデル導出を行った。この研究は、事例研究を採用しており、機械学習を活用しているさまざまな企業に焦点を当てている。企業がどのように機械学習応用システムを活用しているのかを深く理解するため、対象者へ事前打ち合わせを行い、講演資料を準備してもらい、講演と質疑応答を通じてデータコレクションを実施した。いずれのケースも収集されたデータは、帰納的テーマティック・アナリシス法を用いた質的分析を通じて精査された。その結果からモデル導出を行った。




図 3-1 研究の流れ

講演者の選定は、早稲田大学の卒業生や大学と協力関係にある企業リストをリストアップし DX を推進している企業に接触した。講演者のサンプリングにおいて質的研究という手法はサンプリングにおけるサンプリングバイアス、代表性の確保、サンプルサイズの適切さ、一般化の確保といった問題がある。サンプリングバイアスにおいては早稲田大学の卒業生リストからサンプリングをしているためある一定のバイアスがかかっている可能性がある。代表性の確保においては業界をなるべく分散するように意識した。サンプルサイズの妥当性については議論の余地があるが、講演者は日本の CX0 クラスの企業経営者または部長クラスを対象とし、DX を直接推進する人物に限定したため、アクセスの困難を伴うため本研究の限界ともいえる。一般化の確保は DX を実施している日本の企業の役員・部長クラスから経営的な視点からデータコレクションを行い、範囲を限定したことで解決をしている。

講演及び質疑応答に同意した 8 つのケースを分析対象とした。表 3-2 には、講演者及び主な対象となったプロジェクト、業界、講演対象者の役割を一覧にまとめた。プロジェクトはその企業が DX をするうえで最も重要であると判断した取り組みを示している。こ

これはバリューチェーンでいう企業の主活動のシステムであり、企業の根幹を成すシステムである。

なお、講演実施後に発表された経済産業省 DX 銘柄 2023 に本講演者の中から 2 社が選定された。そのためヒアリング先の DX 推進度合いの目利きはある一定の品質を保っていた言えよう。

結果の妥当性について記述したい。データコレクションと分析においては、複数のデータソースを用いて信頼性を確保した。講演と質疑応答の録音データは、テキストに書き起こし、質的データ分析ソフトウェアを用いてコーディングを行った。分析プロセスの透明性を保つために、他の研究者によるレビューを受け、結果の信頼性と妥当性を担保した。分析結果を専門家からフィードバックをもらい練るプロセスを通じて、データの解釈が現実在即していることを確認した。これにより、結果の妥当性が確保されている。

表 3-2 講演対象者

講演者 No.	プロジェクト	業界	講演者役割
講演者 1	在庫配分最適化システム	小売業	CDx0
講演者 2	販売計画システム	広告業	CEO、IT 部門
講演者 3	防災システム	ソフトウェア業	CEO
講演者 4	ウェブアプリケーションファイアウォールシステム	情報通信業	CX0
講演者 5	賃貸収益計算システム	不動産業	CEO, CTO
講演者 6	運転支援システム	運輸業	CX0
講演者 7	駐車場在庫管理システム	不動産業	CX0
講演者 8	ヘルスケアサービス	製造業	研究開発部門マネージャー

講演及び質疑応答は表 3-3 に示すスケジュールで実施された。講演及び質疑応答は以下に示す 2 ステップで行われた。1 ステップ目は趣旨説明と講演の準備依頼、2 ステップ目が講演当日と Q&A セッションである。1 ステップ目では DX の研究のためのデータコレクションを不特定多数の聴衆が参加可能な講演形式で実施する旨と当日までに準備してほしい内容を説明した。当日の講演では 30 分から 40 分の講演を行い、10 分間の質疑応答を実施した。

表 3-3 講演・質疑応答日時

講演者 No.	講演日	時間	方法
講演者 1	2022 年 11 月 16 日	10:30-11:30	Zoom 講演形式＋質疑応答
講演者 2	2022 年 10 月 7 日	15:00-16:00	Zoom 講演形式＋質疑応答
講演者 3	2022 年 12 月 22 日	15:00-16:00	Zoom 講演形式＋質疑応答
講演者 4	2023 年 1 月 13 日	15:00-16:00	Zoom 講演形式＋質疑応答
講演者 5	2022 年 10 月 27 日	14:00-15:00	Zoom 講演形式＋質疑応答
講演者 6	2023 年 4 月 5 日	15:00-16:00	Zoom 講演形式＋質疑応答
講演者 7	2023 年 2 月 2 日	15:00-16:00	Zoom 講演形式＋質疑応答
講演者 8	2023 年 3 月 25 日	16:00-17:00	Zoom 講演形式＋質疑応答

講演内容に含めるように依頼したことは表 3-4 にあるように、主に 3 点である。1 点目が会社の紹介、2 点目が DX の取り組み、3 点目が今後についてである。1 点目の会社紹介では会社の事業内容及び DX を会社として行う背景を含めてもらった。2 点目の DX の取り組みでは、何を対象に DX を行ったか、また、時系列で何から実施したのか、推進するうえで特に意識したことは何か？の 3 点を主に含めてもらった。3 点目は今後どのようなことを行いたいかを講演内容に含めてもらった。これらの内容は講演内で網羅的に話されることが理想的ではあるが、情報が不足している場合は Q&A セッションで追加質問を行う形とした。講演会はオンラインで聴講者を募集し、Zoom で 1 時間実施した。講演が 30 分から 40 分、質疑応答 10 分、別途トピックに沿った情報共有を 10 分から 20 分行った

表 3-4 講演依頼内容

依頼カテゴリ	講演依頼内容
会社紹介	・ 会社の事業内容 ・ DX を行う背景
DX の取り組み	・ 何を対象に DX を行ったか？ ・ 時系列で何から実施したのか？ ・ 推進するうえで特に意識したことは何か？
今後について	・ どのようなことを行いたいか？

セミナーと質疑応答は書き起こされ、質的に分析した。データ分析方法としてテーマティック・アナリシス法(Boyatzis 1998)を採用した。テーマは事例から論理的に導き出し、トランスクリプト、コード、テーマを反復的に反芻する中で最終的なコードを導き出

した。表 3-5 はテーマ、コードとサブコードをまとめたものである。これは次節で説明する DX3 分類の基本となるものである。使用されたソフトウェアは MAXQDA (バージョン 24.2) である。トランスクリプト内の重要な個所にコードを振り、コード間の関係性を可視化できるソフトウェアである。

表 3-5 テーマ、コードとサブコード

テーマ	コード	サブコード
1 型 内部チェーン最適化型 DX	できることから始める	当事者としての問題意識
		まずはデータを集める
	デジタルプラットフォーム活用	データ活用のためのシステム基盤構築
		データ価値の探索
	局所最適から社内全体へ	局所的な成功体験を実績として活用
		前後プロセスへの広がり
2 型 バリューチェーン最適化型 DX	協力会社を巻き込む	結果の見える化推進
		新たな協力関係
	顧客を巻き込む	顧客への情報開示
		エンパワーメント
	データを基にした付加価値向上	試行錯誤
		社外向け付加価値
3 型 新事業価値創造型 DX	1 型, 2 型からのデータ活用	データから得る多様な付加価値
		多様な価値提案による顧客セグメントの拡張
	ビジネスモデル変革	既存データからの新規商品・サービス開発
		課金システムの変更
	探索型アプローチ	M&A をきっかけに
		外部パートナーとの協業をきっかけに

3.4. DX3 分類と主要活動

前節の分析を通して DX3 分類（図 3-2）を導出し各分類で主要な活動を抽出した。1 型 内部チェーン最適化型 DX は、企業内のデータを最適化することから成る。ここでは 2 型、3 型の基礎となるデータを構築する。2 型 バリューチェーン最適化型 DX は、協力会社や顧客といった外部のアクターを巻き込むことで DX のモデルを強化することである。3 型 新事業価値創造型 DX は、1 型、2 型のデータを基に新しいビジネスモデルを構築することを指す。




図 3-2 DX 分類

1 型：内部チェーン最適化型 DX

1 型：内部チェーン最適化型 DX の特徴は 3 つ挙げられる。1 つ目は「できることから始める」、2 つ目は「デジタルプラットフォーム活用」、3 つ目は「局所最適から社内全体へ」である。

1 つ目の「できることから始める」を述べたい。DX の始点は経営者や担当者の強い問題意識により、できることから始めている。業務での多くの課題を 1 つずつ解決しながら進める必要があるため、まずはデータを集めることが重要である。

2 つ目は「デジタルプラットフォーム活用」である。これは人間の仕事を代替する業務を見つけて小さく成功体験を積み上げることが重要である。業務上の多くの課題を 1 つずつ解決する際のプロセスでは部門をまたがるため、DX の取組みによる明示的なメリットが重要となる。また、そのためにはニーズの取り込みを早期化する工夫が重要である。

3 つ目は「局所最適から社内全体へ」である。これは成功を確実にするため、まずは局所的な最適化から始め実績を出してから、前後プロセスに広げていき、徐々に組織全体にスケールする段階的な進捗を指す。

1 型：内部チェーン最適化型 DX の段階でのデータ獲得は、2 型バリューチェーン最適化型 DX および 3 型新事業価値創造型 DX に不可欠である。企業は局所的な最適化から他部門への拡大に際して多くの障壁に直面する。部門間のデータサイロ化が大きな課題の一つである。データ定義、データ前処理、プロセスの統合処理には相応なりソースと投資が必要である。1 型はマーケティングやセールスを対象に推進されることが多く、近年では CDP（カスタマーデータプラットフォーム）の登場により顧客データの統合がトレンドとなっている。それに伴いマーケティング・セールス部門の一元化した顧客データを基にコ

ンタクトセンターや商品開発、バックオフィス部門など部門間のデータ連携が推進されている。本研究では、顧客との接点に基づいて多くのデータが統合されていることが認識できる。

特徴 1-1: 「できることから始める」

DX の取り組みにおいて、「できることから始める」ことは大変重要である。このプロセスは、多くの場合、経営層または部門責任者の強い問題意識から始まり、まずはデータを集めながら小規模な成功体験を積み重ねることで、徐々に企業全体への波及効果を期待するものである。

講演者 2 は、自身の過去の経験から、「現場の仕事は宝の山なのにそれが放置されている」との認識に基づきビジネスを立ち上げた。「店舗の情報をデータベース化する仕組みというのを最初から構築していました」と彼は述べている。この言葉からは、当事者として確固たるビジョンと、それを現実化するための地道な取り組みが感じ取れる。同様に、講演者 3 は東日本大震災を契機に、災害情報の収集と分析に基づくビジネスモデルを構築した。「当時は Twitter ユーザーはそれほど多くありませんでしたが、この情報を整理し、地域別にまとめると役に立つだろうと思いました。これがビジネスの出発点でした。」と彼は述べているが、まずはデータを集めることから始めている。具体的には、オープンデータを整理し価値づけをして提案を繰り返したところから重要なデータを見極めていった。

これらの事例は、DX が単に技術の導入や活用に留まらないことを示している。具体的な問題意識を基に価値創造に向けて小さく、時間をかけて積み上げているのが特徴である。その出発点は、「できることから始める」というシンプルなアプローチにある。実現可能な小さな目標から着手し、その達成を通じてチーム全体のモチベーションと自信を高め、さらなる改善と革新へとつなげる、というプロセスが含まれている。「できることから始める」という特徴は、DX を成功に導くための、基本的だが決定的な要素である。これは、複雑で不確実なデジタル化の時代において、企業が一步步前進し、継続的に成長し進化するための必要な打ち手である。

講演者 2: 広告業

「現場の仕事は宝の山なのにそれが放置されている」という強い問題意識がありました-中略- 弊社は覆面調査というビジネスで起業しましたが、データは蓄積すれば価値になるはずだ、と思って「サービス A」という店舗の情報をデータベース化する仕組みというのを最初から構築していました。それが、やっとなんか 2~3 年で価値として認められてきた、ということです。」

講演者 7

「デジタル知見上手く活用してデジタル集客のレバーをかけたりデータを活用したり生産性を改善したり営業マンをデータドリブンにしたり。(ということをやってきた)」

講演者 3：ソフトウェア業

「東日本大震災が発生した時、従来のマスメディアでは地域別の詳細な情報が伝わってこなかったため、Twitter を見ていると「ここには物資が不足している」とか「ここでボランティアを探している」といったツイートがかなりありました。当時は Twitter ユーザーはそれほど多くありませんでしたが、この情報を整理し、地域別にまとめると役に立つだろうと思いました。これがビジネスの出発点でした。現在では、会社は SNS だけでなく、気象データ、カーナビゲーションシステムからの走行データ、人流データ、衛星データなどを組み合わせてデータ分析を行っています。」

特徴 1-2: 「デジタルプラットフォーム活用」

DX の過程において、「デジタルプラットフォーム活用」は重要なポイントである。ここで主張したいのは、データから得られる知見を企業として活用するために、データ活用のためのシステム基盤構築が重要であり、その過程でデータ価値を探索することが重要である。

講演者 3 の言葉を借りれば、「冬場に起きる道路のスタックを未然に察知するシステムの開発」は、道路上のカメラや車両からのデータを活用し、積雪や視界不良の自動判定を行うものである。「道路に設置されているカメラや車のデータなどを使って」システムを構築するアプローチは、従来であればフローデータとしてそのデータの意味合いを定義できなかったものに価値を見出し、仕組み化している例と言える。

また、講演者 1 からは、「当社は EC でするので、ウェブサイト上のお客様の行動やレビュー、Twitter 等の SNS で世の中の状況を常に分析しています。」と述べられているが、顧客行動や市場トレンドをリアルタイムで捉え、顧客ニーズを迅速に把握するためのデータ基盤の構築が、DX において極めて重要であることを物語っている。

これらの事例から、「デジタルプラットフォーム活用」は、単に技術的な問題解決に留まらず、データを蓄積し、データから得られる知見を企業として活用しようとしていることがわかる。

講演者 3：ソフトウェア業

「もう一つ実証実験中のプロジェクトを紹介しますと、冬場に起きる道路のスタック（車両滞留）の被害を未然に察知するシステムの開発です。道路に設置されているカメラや車のデータなどを使って、積雪の深さなどの道路の路面の状態や、吹雪やホワイトアウトと言ったものを自動判定しようというものです。カメラは道路会社や国土交通省、各自治体が設置しているカメラが全国無数にありますので、これを活かすことになります。」

講演者 1：小売業

「当社は EC です。ウェブサイトでお客様の行動やレビュー、Twitter 等の SNS で世の中の状況を常に分析しています。」

特徴 1-3：「局所最適から社内全体へ」

DX における「局所最適から社内全体へ」は、企業がデジタル化を進める上での重要な戦略の一つである。このアプローチにより、組織は初期段階の局所的な成功体験を基に、徐々にその取り組みを組織全体に広げ、大きな成果を目指すことができる。このプロセスでは、最初に小さな範囲での成功を前後のプロセスに広げていくことで、組織全体への展開の礎となる。

講演者 6 からは、「全車両に搭載したのが今年の 4 月、実用化まで 1 年の実証実験を繰り返しました。最初は 30 台のタブレットと、選抜された 60 名のドライバーからスタートして、さらに 3 か月後に 50 台、100 台、500 台と増やしながら進めていきました」と述べられており、局所的な取り組みから始めて徐々に規模を拡大し、組織全体に対して広げていく過程を示している。

一方、講演者 1 からは、「商品の選定から発注入荷や出荷輸送配送といった全てのプロセスを俯瞰して、最適化を図っていくというのが物流 DX としては非常に重要」と述べており、これは、DX が単に技術の導入に留まらず、組織全体のプロセスを変革する包括的な取り組みであることを示している。「データについても、元々ある色々なデータをお客様基盤中心に統合し」とあり、顧客情報の一元化から社内バリューチェーンを起点に漸進的に進めていることがわかる。

これらのことから、局所的な成功体験を実績として活用し、段階的に前後のプロセスへ対象を広げ、組織全体に展開していくアプローチが重要と判断できる。

講演者 6：運輸業

「全車両に搭載したのが今年の 4 月、実用化まで 1 年の実証実験を繰り返しまし

た。最初は 30 台のタブレットと、選抜された 60 名のドライバーからスタートして、さらに 3 か月後に 50 台、100 台、500 台と増やしながら進めていきました」

講演者 1：小売業

「商品の選定から発注入荷や出荷輸送配送といった全てのプロセスを俯瞰して、最適化を図っていくというのが物流 DX としては非常に重要かと思います。データについても、元々ある色々なデータをお客様基盤中心に統合しつつ、何が問題になっているのか、何をしたら全体がよくなるのかという分析をしながら、プラットフォーム全体を進化させていくということ」

2 型：バリューチェーン最適化型 DX

2 型：バリューチェーン最適化型 DX の特徴は、3 つ挙げられる。1 つ目は、1 型で構築されたデータプラットフォームに協力会社を巻き込むことである。2 つ目はデータプラットフォームに顧客を巻き込むことである。3 つ目はデータを基にした付加価値向上である。

1 型で社内最適化を実現し、これらのメカニズムに協力会社や顧客を巻き込むことで最適化の範囲を拡大する。ここでは協力会社や顧客が関与することで共創を通じてデータを収集することが可能である。ただし、これらの活動は基本的に従来のビジネスモデルに則って行われ、企業は既存のビジネスモデルを深化する段階にある。2 型の前提条件は、協力会社、時には顧客を最適化プロセスに含め、データを基にした付加価値をそれぞれのアクターが享受できることである。これらの前提としてのメカニズムは 1 型で構築したデータ及びデータプラットフォームが重要な位置を占めている。

特徴 2-1：「協力会社を巻き込む」

DX における「協力会社を巻き込む」は、1 型において内部の最適化を概ね実現し、更に協力会社をプロセスに組み入れることで、最適化の範囲を拡大することである。ここで肝要なのは、協力会社が関与することで、共創を通じたデータ収集の効率化とその有効活用範囲の広がりにある。協力会社を巻き込むためには結果の見える化推進と新たな協力関係の構築が必要となる。

講演者 1 によれば、「私たちはスタートアップ段階からデータドリブン指向のビジネスモデルを構成しています。サプライヤーの在庫情報を統合することで在庫切れを防ぎ、利用者の利便性の向上と売上の増加を実現できます。」と述べており、協力会社との連携を通じて、在庫管理の最適化に成功していることを示している。また、講演者 6 は「売上への効果も、アプリを起動している状態では起動していない状態に比べ、6.8%伸びたと

いうデータが出ています。」と語り、デジタルツールを介したパートナーとの協業が具体的な経済効果をもたらしている例を挙げている。

これらの事例から、協力会社を巻き込んだ最適化プロセスは、データを中心にした取り組みが結果の見える化を促進し、そのデータを双方にとって更に利活用するために新たな協力関係の構築が必要である。具体的にはデータプラットフォームの活用に協力会社が積極的になり、データの提供を行うことなどがあげられる。2 型の進行にあたっては、既に 1 型で構築された基盤を活用し、協力会社もこのプラットフォームを活用することで相互のメリットが最大化される。これは、DX を推進する企業がその対象を 1 型の会社内部だけではなくバリューチェーン全体に広げることを意味しており、企業のみならずバリューチェーンに関わるアクターの持続的な成長を目指すためのアプローチである。

講演者 1：小売業

「私たちはスタートアップ段階からデータドリブン指向のビジネスモデルを構成しています。そのため、旧来の企業と比べて部門間のサイロ問題は発生していません。私たちは購買ロジスティクス、在庫管理、出荷ロジスティクスなど多くのプロセスでデータドリブン最適化を実現しています。上記の背景から 1 型はスムーズにスタートしました。サプライヤーの在庫情報を統合することで在庫切れを防ぎ、利用者の利便性の向上と売上の増加を実現できます。適切な在庫配置と出荷ロジスティクスの最適化には大量のデータが必要であり、それらは機械学習応用システムによって自律的に運用されています。」

講演者 6：運輸業

「売上への効果も、アプリを起動している状態では起動していない状態に比べ、6.8%伸びたというデータがでています。機能別に売上効果を見ると、「高需要エリア検索」機能を使った場合、ベテランですと 5.2%、新人では 16.6%売上が上がっています。電車が運休になったりした時に出る「特需通知閲覧」ですが、こちらはベテランも新人も閲覧したドライバーは閲覧しなかったドライバーに比べ 10%ほど売上が伸びている。「イベント情報閲覧」ではベテランと新人では売上増効果に差が出ておりますが、これはベテランドライバーの方がイベント会場がどこにあるかとかが分かっているので、その差かなと思っています。」

特徴 2-2:「顧客を巻き込む」

DX における「顧客を巻き込む」は、1 型において内部の最適化を概ね実現し、顧客をプロセスに組み入れることを指す。ただし、データプラットフォームを直接顧客が触ると

いうことは現実的ではないために顧客にスマートフォンアプリケーションや会員組織を構築してそのうえでやり取りを実施する。顧客を巻き込むうえでは、顧客への更なる情報開示と顧客のエンパワーメントが重要となる。

講演者 2 は広告業界において、「顧客であるメーカーに対して、例えばこういう商品を展開する時にどこの店舗で販促を強化すれば効果的ですよ、という提案をしながら、（販促を強化すべき）店舗リストを無償で提供する代わりに、弊社のデジタルサイネージを導入してください」と述べており、これはデータの提供に引き替え、顧客に新たなサービス提供をしている。また、そこで提供するデジタルサイネージを設置することは小売店での消費者情報のデータを取得することが可能であり自社の情報開示をしながら、新たなサービスで顧客をエンパワーメントしている。講演者 4 は AI による運用者の能力拡張を以下のように述べている。「（顧客を）AI でエンパワーメントする、という考え方です。これは我々や我々の AI が運用者様にとって代わるというものではなくて、運用者様に判断の為の情報を与えるだとか、AI が新規のディレクションに関してもルールだけ作って、あとは適用するかしないかは人にお任せする」。ビッグデータを基にした示唆を顧客に届けることで顧客が自らの業務を効率化し、より良い判断を下す力を付与している。講演者 8 は、「問題はユーザー情報の取得が難しいことでした。ランナーアプリを取得することでランナーコミュニティへのパスを作りました。」と述べており、顧客とスマートフォンアプリケーション上で直接的に繋がることで、ユーザー情報を得て新たなビジネスの機会を創造している。

これらの事例を踏まえると、2 型は顧客との連携を強化し、顧客への情報開示を強めることで、顧客がエンパワーメントされるような仕組みを構築することが、成功に至るための重要なステップである。

講演者 2：広告業

「顧客であるメーカーに対して、例えばこういう商品を展開する時にどこの店舗で販促を強化すれば効果的ですよ、とか、商品のターゲットとする客層が多い店舗はここですよ、という提案をしながら、（販促を強化すべき）店舗リストを無償で提供する代わりに、弊社のデジタルサイネージを導入してください、ラウンダーのサービスを導入してください、販売員の派遣をさせてください、というような営業活動に繋げる、ということを行っています。」

講演者 4：情報通信業

「顧客であるサービスの導入者側の運用者様を、AI でエンパワーメントする、という考え方です。これは我々や我々の AI が運用者様にとって代わるというのではなくて、運用者様に判断の為の情報を与えるだとか、AI が新規のディレクシ

ョンに関してもルールだけ作って、あとは適用するかしないかは人にお任せするというような状態で持っていく、という業務効率化です。」

講演者 8：製造業

「問題はユーザー情報の取得が難しいことでした。小売販売を通じて靴を販売しているため、ユーザーが製品をどのように使用しているかを知ることができませんでした。ランナーアプリを取得することでランナーコミュニティへのパスを作りました。アプリケーションを含むランナーエコシステムの構築というビジョンを持ってビジネスを推進しています。」

特徴 2-3：「データを基にした付加価値向上」

DX における「データを基にした付加価値向上」は、組織が直面する試行錯誤のプロセスと、社外向け付加価値創出が主要な特徴となっている。データの積極活用により、企業は製品やサービスのパーソナライズを推進したり、各種最適化をしたり、専門家のスキルを AI により代替するなどより良い体験を提供している。これは 1 型の社内の前後プロセスに広げていくものとは違い、対象が社外になっている点が新しい。

講演者 8 は、製造業における取り組みについて、「いわゆるビッグデータという考え方もありますし、ビッグデータから学んだものを築き、どういう風にパーソナライズして提供していくかというのが大事なと思っています。1つの ID に紐づけることによってデータを分析できるようにする」と述べており、顧客データを活用し、パーソナライズ化することで新たな付加価値を創出している。更に、「誰もが一生涯スポーツに関わる心と、身体が健康でい続けられる世界を実現したい」とのビジョンを掲げ、新たな顧客層への拡大を見据えている。講演者 2 は、「動画をオンラインで流すとか、朝昼晩流す動画を変えたりとか、視聴率のいい動画に集中したりとか、きめ細かい工夫はしています」と述べており、コンテンツ配信の最適化に力を入れている。講演者 4 は、知識とスキルの再現性について、「我々は AI でそれぞれの専門家のナレッジ・スキルを再現できるようにして、担当者がカバーできる領域を増やしています。専門性をコモディティ化している」と語り、ナレッジベースの構築と AI 活用によってサービス品質を向上させている。これも専門家のナレッジを AI が再現できるように試行錯誤が垣間見える。

これらの事例からデータに基づく付加価値の向上は、データが競争力を維持するための基盤となり試行錯誤しながら社外向け付加価値の創出をしていることがわかる。

講演者 8：製造業

「いわゆるビッグデータという考え方もありますし、ビッグデータから学

んだものを築き、どういう風にパーソナライズして提供していくかというのが大事なかなと思っています。この付加価値をどのように付けるかという、1つのIDに紐づけることによってデータを分析できるようにする、というところが今我々が始めたところです。今まで色々なサービスを提供していましたが、それぞれが別々のIDでログインしなきゃいけなくて、裏のデータベースが連携していなかった状態だったのを、サービスAというシングルIDメンバーシップサービスをすることによってデータがやっとデータウェアハウスに溜まり始めてきたという状況です。

—中略—

今まで当社はアスリートたちへのサポート、特にパフォーマンスアスリートのためのビジネスを中心に展開してきましたが、今後はより広い視野での事業への拡大をしていきたいと考えています。今まではパフォーマンスアスリートでした。今後2030年に向けてVISION2030を作り、“Lifetime Athletes in All of Us”というモットーで、誰もが一生涯スポーツに関わる心と、身体が健康でい続けられる世界を実現したいということでこのメッセージを掲げています。」

講演者2：広告業

「動画をオンラインで流すとか、朝昼晩流す動画を変えたりとか、視聴率のいい動画に集中したりとか、きめ細かい工夫はしています。」

講演者4：情報通信業

「まず1つ目が、専任者のナレッジ・スキルに再現性を持たせ、レバレッジを効かせる、ということです。具体的には、我々はセキュリティサービスを展開している会社で、顧客を担当する者にそれなりの専門性が求められます。しかしその専門性というものは多岐に渡っていて、すべての分野の専門家をすべての顧客に張り付けさせるレベルで確保するのは現実的に不可能です。そこで我々はAIでそれぞれの専門家のナレッジ・スキルを再現できるようにして、担当者がカバーできる領域を増やしています。専門性をコモディティ化している、ともいえるでしょう。」

3型：新事業価値創造

3型：新事業価値創造の特徴は3つ挙げられる。1点目は、1型、2型からのデータ活用。2点目はビジネスモデル変革。3点目は探索型アプローチである。1型で社内最適化を実現し、2型で協力会社や顧客を巻き込むことで最適化の範囲を拡大する。3型では1型、2型のデータを活用することで探索的なアプローチをしながらビジネスモデルを変革する

ことにある。その基なるアクターの協力会社や顧客は 2 型で関係ができているという前提である。

1 点目の 1 型、2 型からのデータ活用については、1 型または 2 型によって生成されたデータに基づいて新たな価値の創造をすることにある。2 点目のビジネスモデル変革は顧客の視点からみて提供される価値と支払い方法が変化することが必要である。具体的には製造業がサービス化するなどの変化である。これらはしばしば課金システム自体の変更が伴う。3 点目の探索型アプローチは新規価値創造にあたって顧客層の変更やより本質的な顧客ニーズの解決、商品またはサービスの抜本的変更を伴いアジャイル的なプロセスである探索型アプローチにより実施される。これらにより、3 型を実現した企業は従来のビジネスとは異なるビジネスへ生まれる変わることを意味する。なお、本業から離れた新規事業を起こすことは 1 点目の要件である 1 型、2 型からのデータ活用が伴わないことが多い。これは新規事業であり、3 型には含まれないことを記しておきたい。

特徴 3-1: 「1 型、2 型からのデータ活用」

DX における「1 型と 2 型からのデータ活用」は、1 型と 2 型のフェーズを経て、データから得る多様な付加価値の創出と多様な価値提案による顧客セグメントの拡張という段階に入る。この段階では、データ活用によって複数の付加価値が顕在化しており、これらにより、特徴 3-2 に述べられている、ビジネスモデルの変革を行う。

「タクシー事業のビジネス特性上、ベテランドライバーと新人ドライバの売上の差は顕著です」と語る講演者 6 の事例は、データ蓄積が如何にして既存のビジネスプラクティスを変革し、新たな価値を創造できるかを示している。同事例では、データベースに蓄積されたベテランタクシー運転手の移動情報を基に、新人ドライバーがどのように行動すべきかを提案しており売上向上に直接貢献している。またこれらのシステムを他タクシー会社への外販も実施しており顧客から運賃をもらうという従来型の運輸業からの転換が確認できる。講演者 4 は、「何をデジタル/AI 化し、何を人がやって、何が人にしかできないか」という観点から、デジタル/AI の適用が人間の能力を強化し、業務の質と効率を高めることが可能であることを示唆している。この認識は、データ活用により、従来人間がセキュリティ保守を行っていたものを、ビッグデータと AI で解析を行い SaaS として提供形態を変更している。

「1 型と 2 型からのデータ活用」とは、単に情報を集めることなく、集めた情報を如何に活用し、新たなサービスやビジネスチャンスに結びつけるかという戦略的思考の展開に他ならない。3 型の文脈では、この戦略的思考はさらに進化し、データから得る多様な付加価値が顧客セグメントの拡張の重要な要素となる。そのため 1 型、2 型の段階を経たデータ蓄積が、新たな価値創造のための必須条件である。

講演者 6：運輸業

「タクシー事業のビジネス特性上、ベテランドライバーと新人ドライバーの売上の差は顕著です。また、タクシーの運転方法はベテランドライバーの暗黙知に蓄積されており、新人に容易に伝えることができませんでした。会社はタクシーの移動情報をデータベースに蓄積し、売上の高いドライバーの特性を調査し、新人ドライバー向けのナビゲーションシステムとして提供しました。これは、エリア検索機能を使用した新人ドライバーに比べて 1.6%の売上増加と、詳細な需要情報の閲覧による 1.9%の売上増加に寄与しました。現在は他の会社にも提供しています。」

講演者 4：情報通信業

「何をデジタル／AI 化し、何を人がやって、何が人にしかできないかというところをちゃんと明確化する。そして人がやらなくてもいいこと、人が得意ではないことに関してはデジタル／AI 化することで、人をエンパワーメントしていく。つまり、人がやらなくてはいけないことに人が集中する世界が「DX が進んだ世界」なんじゃないかな、と個人的に思います。」

特徴 3-2：「ビジネスモデル変革」

DX における「ビジネスモデル変革」は、顧客の新規ニーズを発見し、既存データを活用しながら新規商品・サービスを開発することである。ここでは課金システム自体の変更も伴う。ビジネスモデル変革のためには、市場変化への迅速な対応と、消費者ニーズを発見し、早期に価値提供をすることが重要である。

講演者 2 の広告業における事例では、「私たちは営業スタッフを通じてどの店舗でどのくらいの製品が売れたかのデータをまとめています」と述べ、COVID-19 対応の一環としてデジタルサイネージを使用したプロモーションへの大規模なシフトが行われた。この変革は、過去の販売データを活用して効果的なデジタルサイネージの配置を予測したことで顧客の支持を集め迅速なビジネス展開を実現した。講演者 2 は従来は人材派遣業であったが、この打ち手によりデジタルサイネージを中心とした広告業へと変化した。講演者 6 の「移動時間を、体験時間に」変換するアイデアは、タクシー内でディズニープラスのコンテンツを提供することにより、広告の価値を高める新たな試みであった。「ディズニープラスタクシー」というサービスは、特定のコンテンツとリンクした独自の体験を提供し、SNS 上での高い反響を得ることに成功した。この事例は、運輸業が広告事業を新規に展開し、情報伝達のみならず顧客体験の創造へと進化を示している。

ビジネスモデルの変革は、既存データから新規商品・サービスを開発し、消費者の新

たニーズに応えることが重要である。ビジネスモデル変革は、課金システムの変更も含まれており、新たな製品やサービスの開発に留まらず、市場と消費者の関係を再定義し、持続可能な競争優位を確立するプロセスである。

講演者 2：広告業

「私たちは営業スタッフを通じてどの店舗でどのくらいの製品が売れたかのデータをまとめています。その結果、COVID-19 対応の一環として、営業スタッフ派遣型からデジタルサイネージを使用したプロモーションにシフトしました。過去のデータから、どの販売フロアがデジタルサイネージによって結果につながるかを予測する強みがあります。データによる予測デジタルサイネージビジネスを迅速に立ち上げることを可能にしました。」

講演者 6：運輸業

続いて 3 つ目のビジネスモデル「移動時間を、体験時間に」ということで、さらに広告の価値を上げるサービスをご説明します。これはディズニープラスさんと昨年実施したディズニープラスタクシーというサービスです。

—中略—

SNS 上の反響も非常に好意的でした。インフルエンサーからは「100 台しかない奇跡のタクシーに乗れた」、「車内のシートもディズニー仕様でかわいい」といった投稿、そして一般ユーザーからも「ディズニープラスタクシー 2 種類ゲット」や「美女と野獣のマーブル仕様に乗れた、ラッキー」など沢山の画像も上がり、クライアントのディズニープラスさんも反響の大きさに驚いていたようです。この広告はテレビは雑誌の広告と違い、広告を見た人の反応効果をタイムリーに確認できるので、新しい広告ビジネスの可能性を感じております。今後は 100 台からさらに拡大していく予定です。

特徴 3-3:「探索型アプローチ」

DX における「探索型アプローチ」は、企業が新しいビジネスモデルやサービスを開発する際には、しばしば M&A や外部パートナーとの協業が重要な役割を果たす。このようなアプローチは、既存の組織やサービスの枠を超えて、新たな価値創造の可能性を追求するものである。

講演者 2 は広告業界での事例を挙げ、「2012 年に上場してから販促の領域で M&A をしたり、新会社を設立したりで、今は子会社 10 社とグループを形成しています」と述べている。これは、M&A を活用して新しい技術や市場へのアクセスを獲得し、グループ全体と

しての事業の多角化と強化を図る戦略の例である。講演者 6 は運輸業からの視点を提供し、「資本金も出してサービス A 会社の枠組みの中で進めていくものと、AI の分科会、広告の分科会、タブレットの分科会、マーケティングの分科会と毎週メンバーが決まって議論して新しいビジネスモデルを作っています」と述べ、外部パートナーとの共同作業を通じて新たなビジネスモデルを探求する様子を示している。講演者 5 は「カスタマーサクセス部署を作って、ZOOM で使い方をオンラインで教えたりしている。」と述べ、顧客の技術活用に向けてカスタマーサクセス部署を設立し、オンラインで教育を行い顧客の課題をともに解決するアプローチを採用している。これもまた、組織の枠を超えた、探索型アプローチの一環と見ることができる。

これらの事例から、M&A や外部との協業を通じた探索型アプローチは、企業にとって新しい技術や市場への迅速なアクセス、異なる知見やスキルの統合、そして組織内外の学習と適応を可能にする。本アプローチは、不確実なビジネス環境下での生存と成長に不可欠であり、企業が競争力を維持し続けるためには、探索型アプローチが求められる。

講演者 2：広告業

「2012 年に上場してから販促の領域で M&A をしたり、新会社を設立したりで、今は子会社 10 社とグループを形成しています。デジタルサイネージ事業も、M&A した会社が M&A 以前から長く行っていた事業なのです。」

講演者 6：運輸業

「弊社 1 社で進めていくものもあれば、先ほど申し上げた通り、資本金も出してサービス A 会社の枠組みの中で進めていくものと、AI の分科会、広告の分科会、タブレットの分科会、マーケティングの分科会と毎週メンバーが決まって議論して新しいビジネスモデルを作っていますので、弊社としては自社で進めるものと（サービス A 社の）枠の中でやるものと、どちらにしてもチャレンジ精神を持って進めて行きたいと思っています。」

講演者 5：不動産業

「会社（顧客企業）の中で使っている人と・使っていない人（ベテラン）が分かれている。そのためカスタマーサクセス部署を作って、ZOOM で使い方をオンラインで教えたりしている。」

3.5. DX3 分類の特徴

DX の実践は、社内ビジネスプロセスの最適化から始まり、データの一元化を通じて各部署の連携を強化することにより、効率的な運営を実現する。特に、データを活用する企業文化が初期段階から根付いている組織では、部署間の情報の隔たり、いわゆるデータサイロの問題を回避しやすい。一般的には部署間の情報隔たりは多く認められ、単一部署における局所的な改善から出発し、そこで得られた知見を他の関連部署に広げることで、企業全体の最適化を図る。このようなアプローチによって、ビジネスプロセスは正確性とスピードを増し、全体的な企業のパフォーマンスが高まる。DX の実践においては、各部署からのデータを集積することが、業務改善の出発点となる。各部署で独自に収集されたデータは、一元的なデジタルプラットフォームに集約され、分析や予測を可能にする。統合されたデータの活用は、製品品質向上、顧客サービス改善、さらには市場での新たな機会の発見へとつながる。データの透明性とアクセシビリティが高まることで、組織内の意思決定プロセスはより情報に基づいたものになり、結果としてビジネスの機敏性が向上する。

DX は単に内部プロセスの改善にとどまらず、協力会社や顧客との関係強化にも寄与する。例えば、バリューチェーンの最適化には、協力会社のデータを企業内のシステムに統合することが重要であり、顧客データの活用によるカスタマイズされた製品やサービスの提供は顧客満足度を向上させる。このような協力会社との協調によるデータ共有と活用は、新たなビジネスモデルのきっかけになることもある。データを基にした付加価値も社外に対して提供する 2 型から 3 型ではデータから得る多様な付加価値へと変化を遂げこれにより多様な価値提案が可能となり顧客セグメントの拡張に寄与する。企業は、M&A や戦略的パートナーシップなどの探索型アプローチを通じて、自社のサービスを拡充することができる。1 型、2 型からのデータ活用と探索型アプローチにより、既存データからの新規商品・サービス開発を行い、新たな課金システムを整備することでビジネスモデルの変革を実現する。

DX はデータを活用して全社的な改革を行い、企業がより柔軟かつ効率的に運営を行うための基盤を築くものである。従来のビジネスプラクティスをデジタルの力で刷新し、持続可能な競争優位を築くためには、組織全体でのデータ活用という視点が不可欠である。これにより、部署間の壁を取り払い、部門横断的な連携を促進することで、DX は企業の俊敏性を高める。組織はデータ駆動を基にした運営により迅速さを増し、ビジネス機会を先取りすることが可能になる。特に、組織内外のデータを活用したビジネスモデルの変革は、革新的なサービスの提供、顧客経験の向上、および新しい市場セグメントへの進出を可能にする。

1 型では、社内のデータ整合性とアクセスの向上に注力し、2 型では外部とのデータ共有を促進し、ビジネスエコシステム全体の最適化を目指す。そして 3 型に至っては、これらのデータを活用し、さらには M&A や戦略的パートナーシップを通じて新たなビジネス機会を模索し、市場における存在感を強化するものである。3 型におけるこのプロセスは探索型アプローチとして定義され、M&A を契機に生まれる新たな価値提案や、外部パート

ナーとの協業を通じたサービス拡張など、アジャイルかつ探索的なアプローチは企業が市場で成功するために重要な手法となる。例えば、「2012 年に上場してから販促の領域で M&A をしたり、新会社を設立したりで、今は子会社 10 社とグループを形成しています」と述べる講演者 2 の広告業界における経験は、DX の探索型アプローチの有効性を示す一例である。また、「弊社 1 社で進めていくものもあれば、資本金も出してサービス A 会社の枠組みの中で進めていくものと、AI の分科会、広告の分科会、タブレットの分科会、マーケティングの分科会と毎週メンバーが決まって議論して新しいビジネスモデルを作っています」との講演者 6 の言葉は、外部との協業を進めながら新たなビジネス機会を生み出す 3 型の形を表している。

DX3 分類を通して、DX が企業にもたらす価値は、社内外のデータ統合だけに留まらず、革新的な新事業価値創造も含まれることが理解できる。組織は変革をリードし、絶えず新しい価値を顧客に提供するためには、DX3 分類で定義されているステップを 1 つずつ実行することが重要である。DX3 分類ごとの特徴と講演者の対応表を表 3-6 にまとめた。

表 3-6 DX3 分類の特徴と講演者対応表

No.	DX 分類	特徴	講演者 1	講 -2	講 -3	講 -4	講 -5	講 -6	講 -7	講-8
1-1	1 型	できることから始める	Y	Y	Y	Y	Y	Y	Y	Y
1-2	1 型	デジタルプラットフォーム活用	Y	Y	Y	Y	Y	Y	Y	Y
1-3	1 型	局所最適から社内全体へ	Y	Y	Y	Y	Y	Y	Y	Y
2-1	2 型	協力会社を巻き込む	Y	Y	Y	Y	Y	Y	Y	Y
2-2	2 型	顧客を巻き込む	N#2	Y	Y	Y	Y	Y	Y	Y
2-3	2 型	データを基にした付加価値向上	Y	Y	Y	Y	Y	Y	Y	Y
3-1	3 型	1 型, 2 型からのデータ活用	N#1	Y	Y	Y	Y	Y	Y	N#1
3-2	3 型	ビジネスモデル変革	N#1	Y	Y	Y	Y	Y	Y	N#1
3-3	3 型	探索型アプローチ	N#1	Y	Y	Y	Y	Y	Y	Y#1, 3

まず DX3 分類に沿ってテーマ (DX 分類) とコード (特徴) を縦軸に記し、横軸にはそれぞれの講演者を記した。それぞれの講演者にテーマとコードに即した特徴があるかを事後的に分析した。特徴が認められるものには Y、特徴が認められないものには N とした。3 点の論点が発見できるためそれぞれ記す。

論点 1 (#1) 講演者の DX3 分類

講演者 1 小売業及び講演者 8 製造業は 2 型で分類した。

これは講演者 1 は電子商取引を主とした小売業であるが 3 型の特徴である 1 型、2 型からのデータ活用を基にビジネスモデルの変更が伴わなかったためである。講演者 8 製造業はランナーコミュニティーアプリを買収しており、探索型アプローチは認められるものの、1 型、2 型からのデータ活用やビジネスモデル変革の特徴は認められなかった。

論点 2 (#2) No. 2-2 顧客を巻き込む

No. 2-2 顧客を巻き込むについては全講演者に認められる特徴ではなかった。ただし 8 社の講演者のうち 7 社が対象となっており、よく認められる特徴である。

講演者 1 小売業は DX の対象が物流および取引先をメインとしている。ただし、顧客からの情報については CRM、EC システムで取得ができており、意図的にユーザーを巻き込んではいないが十分に顧客情報がとれている。そのため、2 型のバリューチェーン最適化自体は実施できているという判断をした。またバリューチェーン全体で取引先や顧客が存在するが 2 型では顧客及び取引先の巻き込みについては特徴としては認められるが、2 型と分類するにあたって必須条件ではないと判断できる。

論点 3 (#3) No. 3-3 探索型アプローチ

講演者 8 製造業はランナーコミュニティーアプリを買収し、アプリにより顧客情報へのコンタクトが可能となっている。ただし、ビジネスモデル自体は靴メーカーであり、ランナーコミュニティーアプリを基にしたサービス業には未だ変革ができていないわけではない。本件については、知識科学の研究者とディスカッションを行い、3 型企业として認識するうえでどう解釈するべきかを議論した。結論としては社員、世の中の人企業が靴メーカーとして認知するかサービス業として認知するかにあるという結論に達した。その観点でも講演者 8 の製造業は靴メーカーという認知が主であり、ビジネスモデルの変革に入っていないため 2 型とした。

講演者ごとのプロジェクト概要及び DX3 分類、コード特徴について改めて表 3-7 にまとめた。

表 3-7 講演者の DX3 分類と特徴

講演者 ID	Pjt ID	プロジェクト	DX 分類	1-1	1-2	1-3	2-1	2-2	2-3	3-1	3-2	3-3
講演者 1	Pjt 1	在庫配分最適化システム	2 型	Y	Y	Y	Y	N	Y	N	N	Y
講演者 2	Pjt 2	販売計画システム	3 型	Y	Y	Y	Y	N	Y	Y	Y	Y
講演者 3	Pjt 3	防災システム	3 型	Y	Y	Y	Y	Y	Y	Y	Y	Y
講演者 4	Pjt 4	ウェブアプリケーションファイアウォールシステム	3 型	Y	Y	Y	Y	Y	Y	Y	Y	Y
講演者 5	Pjt 5	賃貸収益計算システム	3 型	Y	Y	Y	Y	Y	Y	Y	Y	Y
講演者 6	Pjt 6	運転支援システム	3 型	Y	Y	Y	Y	Y	Y	Y	Y	Y
講演者 7	Pjt 7	駐車場在庫管理システム	3 型	Y	Y	Y	Y	Y	Y	Y	Y	Y
講演者 8	Pjt 8	ヘルスケアサービス	2 型	Y	Y	Y	Y	Y	Y	N	N	Y

2 型 と 3 型 には、それぞれ両利きの経営における深化と探索の特徴が認められる。2 型では、1 型で構築したシステムに取引先や顧客を組み込むことで、より広範囲でメリットを享受できるようになる。2 型は 1 型の正統進化版である。そのためこれは両利きの経営における深化に該当する。対する 3 型は 1 型、2 型に比べて明確な意図を持って進める必要がある。これは両利きの経営における探索に該当する。実験的にデータを取得しながら方向性を模索し、新しい付加価値を探索し、顧客に提供するアプリケーションを試行錯誤することなどである。これらを進めるためには、Sebastian et al. (2017)は、社内データを管理し、ユーザーの購入データやソーシャルメディア情報などの新しい情報を集めるために、機敏性と迅速なイノベーションが必要であると提案している。3 型では新しいビジネス創造のためにリーンスタートアップやビジネスモデルキャンバスなどアジャイルおよび DevOps の方法論を使用しており、これらは表 3-8 に示す、新規事業の創造方法論 (Rise 2011, Osterwalder 2004, Blank & Dorf 2020, 奥田ら 2021) に詳しい。

表 3-8 新規事業創造方法論

著者	年度	論文名	概要
Eric Ries	2011	The lean startup: How today's entrepreneurs use continuous innovation to create radically successful businesses	製品開発サイクルを短縮し、市場のニーズに迅速に適応するための「リーンスタートアップ」メソッドを提案する。最小限の機能を持つ製品（MVP）を早期に市場に投入し、顧客のフィードバックを基に継続的に改善を行うプロセスを BUILD、Measure、Learn の 3 ステップで実施するように提言。
Blank and Dorf	2020	The Start-up Owner's Manual: The Step-By-Step Guide for Building a Great Company	スタートアップを成功に導くための実践的なガイドを提供。顧客開発モデルと名付け 1. 顧客発見、2. 顧客実証、3. 顧客開拓、4. 組織構築の提唱をした。顧客開発プロセスを中心に、製品の市場適合を実現するためのステップが詳述されている。
Alex Osterwalder et al.	2010	Business model generation: a handbook for visionaries, game changers, and challengers	ビジネスモデルキャンバスという視覚的なツールを用いて、ビジネスモデルを可視化するためのフレームワークを紹介する。9つの基本要素（価値提案、顧客セグメント、チャネルなど）を用いて、企業のビジネスモデルを体系的に構築・分析する方法が説明される。
奥田聡・更田誠・大江建	2021	中小ものづくり企業の生き残り戦略	中小金属加工企業の事例を通じて、市場規模が縮小している中でも成長を遂げることができた理由を探究している。この企業が下請け中心のビジネスモデルからものづくり総合支援サービスを提供する企業へと変貌し、成功を収めた過程を分析し、中小ものづくり企業の生き残り戦略を明らかにする。エフェクチュエーション理論と両利きの経営を用いて、中小企業経営者の行動原則と新規事業の創出を説明し、産学連携を活用した事業探索の方法がモデル化された。

3.6. DX の進化過程と進化パターンの分析

DX の進化は、1 型から始まり、徐々に 2 型を経て 3 型に至るという一連の進化過程を辿る。このプロセスは、内部チェーン最適化、バリューチェーンの最適化、そして新たなビジネス価値の創造に至るまで、段階的に進行する（表 3-9）。しかし、特定のケースではこの進行が異なることが確認でき、企業の戦略や業界の特性によって左右されることがわかる。

6 つの 3 型に至ったケースを詳細に観察した結果、本論文では進化過程は 3 つの進化パターンに分類できると提案したい。1 点目はオペレーションエクセレンス型、2 点目は自己充足型、3 点目は共創型である（表 3-10）。

1 点目のオペレーションエクセレンス型から説明する。講演者 7 の例では、1 型から始まり、2 型を経て 3 型に至るまでのプロセスが非常にスムーズであることが観察される。彼らのアプローチは、外部パートナーとの多数の協力関係に基づく成熟したビジネスモデルであり、オペレーションエクセレンスが実現されている。この種のビジネスでは、業界のペースに合わせる必要があり、外部パートナーとの密な連携と時間を要する調整が不可欠である。この手法を採用するビジネスは、サプライチェーン構造に与える影響を最小化すべく時間をかけて調整を行うことに大きな特徴がある。

2 点目の自己充足型は 2 型のステップを飛ばし、直接 3 型へと移行しているケースである。講演者 2 及び講演者 5 の事例では、バリューチェーン全体にわたるサプライヤーとの連携を待つことなく、独自のデータリソースを活用し、新しいビジネスモデルへのシフトを試みている。これは、企業が独自のデータを準備し、それを基にビジネス変革を遂行する能力により 3 型が推進できることを示している。バリューチェーンの観点から、データを得るためにサプライヤーや顧客と協力する必要性がなく、すべてを内製化していることが大きな特徴である。これにより、外部依存を最小限に抑え、迅速かつ柔軟に市場の変化に対応している。

3 点目の共創型を説明する。講演者 3、4、および 6 の事例は、3 型と 2 型を同時に進行させている。この特性は業界の結びつきが少ない新しい業界や SaaS モデルにみられる。SaaS モデルによるビジネスは、顧客のデータを収集し、そのデータを活用してサービスを進化させることが多い。顧客との共創を通じてデータを収集し、サービスレベルを向上させ、バリューチェーンの最適化を行っている。

表 3-9 DX 進化過程

講演者 ID	1型 内部チェーン最適型DX	2型 バリューチェーン最適型DX	3型 新事業価値創出型DX	顧客価値
講-1	社内物流システムの最適化	メーカー在庫とEC在庫を連動	-	在庫切れを防ぐ
講-2	スタッフによるデータ蓄積	-	デジタルサイネージ事業	小売プロモーション企画の共同制作
講-3	オープンデータ収集	ユーザー参加	防災SaaS	早期の洪水シミュレーション
講-4	オープンデータ収集	SaaS（ユーザーデータ収集）	Webアプリケーション FireWall SaaS	Webアプリケーションファイアウォールサービス
講-5	オープンデータ収集	-	不動産収入シミュレーションSaaS	不動産収益シミュレーション
講-6	社内のドライバーデータの蓄積	ユーザー参加	業界内の運輸業向け運転支援システム	タクシー運転手支援ナビゲーション
講-7	オペレーションによるデータ収集	サプライヤーによるデータ登録	駐車場メディア事業	駐車場のリアルタイム可視化
講-8	社内ID統一化、事業買収	ユーザー接点による商品販売	-	ヘルスサービスプラットフォーム

表 3-10 DX 進化パターン

進化パターン	進化過程	特徴
オペレーション エクセレンス型	1 型 → 2 型 → 3 型	多数のサプライヤーを含む製造業など、パートナー企業との協業が必要なビジネスに適した DX 進化パターン。1 型から始め、内部データ蓄積からパートナー調整の段階を経て、最終的に 3 型に到達することが一般的である。
自己充足型	1 型 → 3 型	情報が豊富でパートナー企業との協業が少ない DX 進化パターン。2 型をスキップし、自社のデータを活用してパートナー企業のデータに頼らずに直接 3 型を実現する。
共創型	1 型 → 2 型及び 3 型 並行	サービス品質を改善するためにユーザー情報を収集することが重要なビジネスに適した DX 進化パターン。2 型と 3 型が並行して進み、顧客フィードバックを取り入れてサービス品質を改善することに焦点を当てる。SaaS 型ビジネスはこのカテゴリに含まれる。

3.7. 小括

DX の進化は、社内最適化を対象とする 1 型内部チェーン最適化型 DX から始まり、最適化された社内のメカニズムに協力会社や顧客を巻き込む 2 型バリューチェーン最適化型 DX を経て 3 型新事業価値創出型 DX に至るという一連の進化過程を辿る。このプロセスは、段階的に進行するものの、企業の戦略や業界の特性によってこの進行に 3 つのパターンがあることが分かった。1 点目は外部パートナーとの多数の協力関係に基づく成熟したビジネスモデルを特徴とするオペレーションエクセレンス型、2 点目はデータを得るためにサプライヤーや顧客と協力する必要性がなく、すべてを内製化している自己充足型、3 点目は、業界の結びつきが少ない新しい業界や SaaS モデルにみられる共創型である。

1 型内部チェーン最適化型 DX 及び 2 型バリューチェーン最適化型 DX は既存のものを拡大・強化する「発展」に概念的には近い。3 型新事業価値創出型 DX はビジネスモデルを変革するという大きな変化を伴い「変革」に概念的には近い。ただし 1 型から 3 型までのプロセスを通して見ると「発展」では説明がつかず、「変革」では 3 型の要素が強すぎるため、環境変革に着目し徐々に改良・適応していく「進化」という言葉で説明した。

4. DX 実行意思

4.1. DX 実行意思の研究目的とアプローチ

DX は現代の企業経営において避けて通れないテーマである。前章では、DX を行う企業の特徴についての考察を行い、特定のパターンや傾向が見られることを示唆した。しかし、これらの特徴が DX の成功にどのように寄与するのか、そのメカニズムはまだ不透明である。本章では、DX を推進する従業員の意識に焦点を当て、これらが DX にどう影響を与えるのかを探究する。

4 章 2 節の一次分析では先行研究からのモデル導出と、29 件のデータによる共分散構造分析を実施し、考察を行った。ただし、データコレクション先が DX 研修であったため集められるアンケート数に限りがあった。4 章 3 節の二次分析では一次分析で得られた結果を基に主成分分析によるアンケート項目の整理と新しい概念の追加を行い 200 件のデータを収集し、再度共分散構造分析を実施し、考察を行った。

4.2. DX 実行意思の一次分析

4.2.1. 研究方法

DX 実行意思の一次分析の研究方法は以下図 4-1 のとおりである。本研究の先行研究調査、モデル仮説導出は 4 章 3 節の二次分析でも同様のモデルを活用している。




図 4-1 研究の流れ

モデル仮説の導出にあたり、DX を推進する動機が新規事業に対する意欲と同質のものであるという仮説を立てた。この仮説に基づき、Theory of Planned Behavior (ICEK AJZEN 1991) のモデルを援用した田路ら (2018) の大学生の起業意識調査レポート-GUESS2016 を参考にして、モデル仮説を導出した。前処理は Python、共分散構造分析で SmartPLS Ver4.1.0.2、単純集計は MS Excel Ver2403 を用いた。

また、DX に必要なスキルセットは、トランスフォーメーションパターンランゲージ (独立行政法人情報処理推進機構 2023) から引用し、これらを統合したモデル仮説図 4-2 を構築した。




図 4-2 第一次 DX 実行意思モデル仮説

データ収集は、29 名の被験者を対象にアンケート調査によって行われた。アンケート対象者は DX 研修に参加した企業担当者であり主な部門は DX 部門、情報システム部門、事業部門（ユーザー部門）であった。アンケート対象者の属性を表 4-1 にまとめた。アンケート項目は備考に添付する。

表 4-1 アンケート対象者

業界	部門	調査対象数
貸貸業・サービス業	DX グループ / IT グループ	3
医療、福祉業	経営企画本部 DX 推進室	3
情報通信業	デジタル統轄部 D2C 戦略部 / エンタープライズシステム部	4
電気・ガス・熱供給・水道業	情報システム部	3
化学工業	情報システム部	2
卸売・小売業	システムソリューション事業部 / デジタルリテール推進本部	3
製造業	事業開発部 / 素形材事業部門	4
電気機械器具製造業	戦略本部 DX 推進部/ ICT 戦略企画部	4
情報通信業	生産革新推進二部	3

定量分析における被験者数が 29 名と少数であることは分析結果の信頼性と妥当性に影響する。本分析結果による結果の一般化は注意が必要であり、今回のサンプル入手元の DX 研修を受けた被験者の特徴を導き出すことはできるが、本制約を基にした結果として解釈する必要がある。ただし、本サンプルは DX に関わる企業担当者でありサンプルの代表性は満たしているといえる。

4.2.2. 分析方法とデータ品質

分析の流れは、アンケートデータを名寄せを行い統合することから始めた。次に、R-Square と Chronbach's alpha 及び AVE を用いて、モデルの予測がデータに適合しているか、測定された項目の一貫性や信頼といった品質面の検証を行った。その後、共分散構造分析を実施した。共分散構造分析は以下の流れで実施した。まず初めにモデル仮説に従い、パス図を作成した。次に、各因子間の相関関係を明らかにしパスの有効性を検証した。本分析には SmartPLSVer4.1.0.2 を用いた。

収集したデータの信頼性と妥当性を評価するために、R-Square と Chronbach's alpha 及び AVE を使用して品質を検証した。R-Square 値はモデルがデータの変動をどれくらい説明できているかを示すもので、0 から 1 までの値をとる。1 に近いほどモデルの予測がデータに適合していることを意味し、0 に近いほど予測がデータに適合していないことを意味する。一般的に R-Square 値は 0.25 以下は低い、0.5 は中程度、0.75 以上と解釈する。表 4-2 が示す通り、DX type と Perceived competence, Subjective norm はその観点から

潜在変数が観測変数を代表していない。その他の値は概ね問題がない。共分散構造分析における R-Square の低さは従属変数が分散していないことを示しておりモデルの説明力が弱く、ほかのデータセットに対する展開時に一般化能力が低いモデルであるといえる。この点を解消するために、4 章 3 節で設問の見直しを含めた二次分析を実施する。本節では少ないサンプルを基に議論を展開する。なお、本サンプルは DX 研修を受講した DX を実際実施している方のため、そのサンプル選定やアンケート回答品質は高いと推定できる。

表 4-2 R-Square 値

因子	R-square
Attitude toward DX	0.372
DX intention	0.698
DX type	0.050
Locus of control	0.856
Perceived competence	0.105
Subjective norm	0.158

Chronbach's alpha は、測定された項目の一貫性や信頼性を評価する指標である。一般的に、アルファ値が 0.7 以上であれば、項目が高い内的一貫性を持っていると考えられる。また AVE は構成概念の測定がどの程度信頼性があるかを判断するための統計的指標であり、観測変数をどれだけとらえているかを説明する指標である。一般に AVE が 0.5 以上であると、その構成概念の指標がその構成概念の大部分を捉えており、測定の妥当性が高いとされる。

表 4-3 Cronbach's alpha 値及び AVE 値

Construct	Cronbach's alpha	Average variance extracted (AVE)
Attitude toward DX	0.873	0.663
Biz transform capabilities	0.928	0.529
DX program climate	0.943	0.780
DX program learning	0.925	0.815
DX intention	0.924	0.767
Locus of control	0.732	0.533
Perceived competence	0.898	0.624
Subjective norm	0.753	0.581

4.2.3. 研究結果と分析

PLS-SEM（部分最小二乗構造方程式モデリング）の結果を表すパスダイアグラムを作成した（図 4-3）。青い円は潜在変数、矢印は潜在変数間の仮定された因果関係、数字は因果関係の強さを示すパス係数を表している。円内の数字は、その潜在変数の信頼性を示す R-Square 値である。観測変数と説明変数の関係性は反映モデルと形成モデルが選択できるが、各観測変数は被験者の信念を計測した反映的な関係性であり、共変動性がみられる。これらのことから反映モデルを採用した。

本研究における共分散構造分析の結果は、DX の行動意図形成に対する複数の重要な潜在変数を明らかにしている。結果、以下の点が確認された。

1. DX 分類(DX evolution type)と DX 実行意思(DX intention)との間に直接的な相関関係は確認されなかった。この結果は、DX に取り組む際の実行意思は DX の分類における進化に直接的な影響を与えていないことを示唆している。
2. DX 実行意思(DX intention)とスキルや能力に関する自信 (Perceived competence) との間には、強い正の相関関係が見られた。これは、DX の担当者が自己スキルや能力に対する自信を持つと、DX に対する実行意思が高まるという結果を示している。
3. スキルや能力に関する自信 (Perceived competence) が高いほど、DX 能力 (Biz transformation Capabilities) が高まるという強い正の相関関係が見られた。これは、スキルや能力に対する自信が高いとトラパタ（独立行政法人情報処理推進機構 2023）で定義されている DX 能力も高いことを示している。
4. 一方で、周囲の承認 (Subjective norm) と DX 実行意思との間には中程度の正の相関関係が確認された。責任感 (Locus of control) と DX 実行意思との間には低い負の相関関係が確認された。DX に対する態度 (Attitude toward DX) は DX 実行意思(DX intention)に対する直接的な影響は少ない。

以上の結果から、DX に対する実行意思を高めるためには、個々のスキルや能力に対する自信の促進と周囲の承認に焦点を当てることが有効であることが明らかになった。




図 4-3 第一次 DX 実行意思モデルの分析結果

本分析を経て更新したモデルを図 4-4 に示す。太線はパス係数が 0.6 以上、実線はパス係数が 0.4 以上であり 0.6 未満、点線はパス係数が 0.2 以上であり、0.4 未満を現している。




図 4-4 第一次 DX 実行意思モデル

4.3. DX 実行意思の二次分析

4.3.1. 研究方法

DX 実行意思の二次分析の研究方法は以下図 4-1 のとおりである。4 章 2 節と同じく先行研究調査、モデル仮説導出を行いその後データコレクションを行った。二次分析では有償アンケートサービスでデータを収集した。その後、共分散構造分析にかけモデルの立証と考察を行った。




図 4-5 研究の流れ

前節でも援用した大学生の起業意識調査レポートに加えて人間機械協働因子を導き出すために Siau and Wang 2018 を設問設計に活用した。また、新規設問の追加として 3 章で記述した DX 進化及び DX 結果、5 章の機械学習応用システムの深化を問う設問を追加した。これらを統合したモデル仮説図 4-6 を構築した。また、1 次分析では設問数が多かったため、主成分分析 (Principal Component Analysis) により因子ごとに設問の見直しを行った。因子内の主成分の負荷量が主成分軸で最も大きいものを本設の分析で質問として選定した。この結果 38 問→13 問へと減らすことができた。また、DX attitude, DX intention, Subjective norm については用いる設問や文言を文脈に合うように一部修正し

ている。前処理は SPSS Ver29.0.2.0(20)、主成分分析は Orange Ver3.36 及び SPSS Ver29.0.2.0(20)、共分散構造分析で SmartPLS Ver4.1.0.2、単純集計は MS Excel Ver2403 を用いた。




図 4-6 第二次 DX 実行意思モデル仮説

データ収集は、200 名の被験者を対象にアンケート調査を行い、171 の有効回答を得た。アンケート対象者は有料アンケートサービスにより実施した。アンケート配信対象として、前節の DX 研修に参加した企業担当者のプロフィールを参考にアンケート対象者のスクリーニング条件を表 4-4 にまとめた。アンケートは事前調査で DX を推進する立場であるかを問い、「はい」と答えた被験者のみを対象に本調査を実施した。用いたアンケート項目は付録に添付する。

表 4-4 アンケート対象者のスクリーニング条件

性別	男女両方
年齢（10 歳刻み）	30 代、40 代、50 代
都道府県	東京都、愛知県、大阪府
職業	会社勤務（一般社員）、会社勤務（管理職）、会社経営（経営者・役員）

業種	土木・建設・不動産・住宅・建物サービス / 通信・金属・物流 / 飲料・食品・小売・医薬品・ガラス・規格品・水産・化石品・トイレリー製品・ヘアケア製品 / 通信 / 鉄道・衣料 / 織・バルブ・木材 / その他情報サービス業 / 国用車種・文書・事務用品 / 銀行・信託・信金 / 個人 / 医療品・健康品・薬品・化学・石油化学 / 信託・消費者金融 / 銀行・非銀行金融・金属 / 油脂・石油・ガス・商品先物 / 有機ガス・消費税法・個人・非銀行金融・金属 / 有機ガス・消費先物及び / 商品・業態・輸送用機器 / 生命保険・自動車保険 / 個人保険サービス業 / 自動車 / 化粧・その他製薬業 / 理容・美容関連 / 化粧・印刷 / その他サービス業 / 新聞・放送・マスコミ・広告 / 情報機器 / 衣服サービス / 商社・卸売 / 繊維・衣料品 / 自動車・スーパー・コンビニエンスストア / その他 / その他流通・小売業
----	--

一次分析では定量分析における被験者数が 29 名と少数であり p 値が有意な値を示さなかった。これは分析結果の信頼性に問題があったことを示している。二次分析では一次分析を受けて、5 点の目的を設定した。1 点目に分析結果の信頼性を上げるために被験者数を増やした。2 点目に一次分析で相関関係が出なかった DX 分類と DX 実行意思の調査設計を見直し、DX 分類は 3 章 4 節の DX3 分類のモデルを設定化することで詳細化した。3 点目に設問数が多かった DX 実行意思を構成する因子の設問数を主成分分析で減らした。4 点目に 5 章 6 節 2 項で分析に用いる人間機械協働因子の取得を新たに行った。5 点目に MLS 深化の設問を追加し DX 分類とのつながりを分析した。

4.3.2. 分析方法とデータ品質

分析前の前処理として 2 点の処理を行った。1 点目に、アンケート回答のうち「わからない／答えられない」と答えた不明回答を中央値で代入した。出現率は各説明変数で 0～7%となり、平均出現率は 3.8%であった。2 点目にアンケート回答を機械的に同一の回答をしている無効回答を除外した。これは 29 件存在した。なお、論理的な矛盾をチェックする設問は用意していない。これらの情報を因子別にまとめた。

表 4-5 第二次因子別回答情報統計

因子	設問数	標準偏差	中央値	最頻値	不明回答出現率
1. 部門	1	1.67	4	4	0%
2. プロジェクト情報	1	1.18	3	3	3%

3. DX 結果	1	1.05	3	3	3%
4. DX 進化	10	1.29	3	3.1	6%
5. MLS 深化	1	0.89	2	2	0%
6. 人間機械協働	5	1.21	3	3	3%
7. DX に対する態度	3	1.19	3	3	3%
8. 周囲の承認	2	1.19	3	3	4%
9. 責任感	3	1.13	3	3	3%
10. スキルや能力に関する自信	3	1.25	3	3	3%
11. DX 実行意思	2	1.24	3	3	3%

※標準偏差、中央値、最頻値、不明回答出現率はすべて因子内平均を表す

データ品質の確認は、R-Square と Chronbach's alpha 及び AVE を用いて、モデルの予測がデータに適合しているか、測定された項目の一貫性や信頼といった品質面の検証を行った。本章 2 節 2 項にそれぞれの値の基準を記載しているので参照されたい。表 4-6 が示す通り、DX outcome と MLS exploitation の潜在変数が観測変数を代表していない。その他の値は問題がない。共分散構造分析における R-Square の低さは本章 2 節 2 項でも示した通り、従属変数が分散していないことを示しておりモデルの説明力が弱く、ほかのデータセットに対する展開時に一般化能力が低いモデルであるといえる。

表 4-6 第二次 R-Square 値

因子	R-square
DX evolution types	0.435
DX intention	0.623
DX outcome	0.139
DX3	0.309
HMC factor	0.572
MLS exploitation	0.014
DX recognition	0.407

表 4-7 が示す通り、Chronbach's alpha 値は Subjective norm は内向性が低く、品質的に課題があるといえる。一次分析から Subjective norm の設問項目は主成分分析により設問数 4 問を 2 問へ削減し設問文も本調査に沿う形に微修正をした。本設分析では各因子

を割り引いてみるものの分析対象としては取り入れる。

表 4-7 Cronbach' s alpha 値及び AVE 値

Construct	Cronbach's alpha	Average variance extracted (AVE)
Attitude toward DX	0.786	0.700
DX evolution types	0.885	0.523
DX intention	0.765	0.810
DX3	0.754	0.671
HMC factor	0.848	0.623
Locus of control	0.762	0.678
Perceived competence	0.809	0.723
Subjective norm	0.681	0.757

その後、共分散構造分析を実施した。分析は 2 つの手順で進めた。まず初めにモデル仮説に従い、パス図を作成した。次に、各因子間で t 検定を行い、p 値の確認を行い統計上有意かを確認した。t 検定の結果を表 4-8 に記す。赤字で示した箇所の p 値が有意水準目標の 5%を超えており、統計上有意ではない。次にパス図の因子間相関係数をもとにモデル仮説の有効性を検証し、有効なパスを整理し、モデル図を最終化した。

表 4-8 因子間標準偏差・T 検定・p 値

因子	Standard deviation	T statistics	P values
Attitude toward DX → DX intention	0.120	2.418	0.016
DX evolution types → HMC factor	0.051	12.147	0.000
DX evolution types → MLS exploitation	0.078	1.539	0.124
DX intention → DX evolution types	0.088	5.343	0.000
DX intention → DX outcome	0.092	2.774	0.006
DX intention → DX3	0.086	4.828	0.000
DX3 → DX3 recognition	0.056	11.285	0.000
Locus of control → DX intention	0.124	1.466	0.143
Perceived competence → DX intention	0.087	3.687	0.000
Subjective norm → DX intention	0.094	0.780	0.436

4.3.3. 研究結果と分析

PLS-SEM（部分最小二乗構造方程式モデリング）の結果を表すパスダイアグラムを作成した（図 4-7）。PLS-SEM の具体的な項目の説明については 4 章 2 節 2 項を参照されたい。本分析には SmartPLSVer4.1.0.2 を用いた。本研究における共分散構造分析の結果は、DX の行動意図形成に対する複数の重要な潜在変数を明らかにしている。分析の結果、以下の点が確認された。

1. DX 実行意思(DX intention)と DX 分類(DX evolution type)との間に強い正の相関関係を確認できた。これは 3 章 4 節で示した DX3 分類と本章で示した DX 実行意思につながりがあることを示せたといえ、4 章 2 節で立証できなかったつながりを確認ができた。
2. DX 分類(DX evolution type)と人間機械協働因子（HMC factor）の間に強い正の相関関係が認められた。この結果は DX 分類が上がっていくことで人間・機械協働で必要とされる要素の重要度が上がることを示している。人間機械協働の因子については 5 章 6 節 2 項で分析する。
3. DX 実行意思(DX intention)と DX 結果（DX outcome）の間には、中程度の正の相関関係が見られた。DX 実行意思が高いと被験者の期待／計画通りに DX が進んでいることを示している。DX 実行意思を高めることができれば期待／計画通りに DX が進めることができると捉えることができ DX 実行意思を高める要素が重要であると言える。
4. スキルや能力に関する自信（Perceived competence）と DX に対する態度（Attitude toward DX）は、DX 実行意思(DX intention)との弱い正の相関関係が見られた。これは、スキルや能力に対する自信や DX に対する態度が DX 実行意思に影響すると推察でき、DX 実行意思を高めるためにはスキルや能力に関する自信と DX に対する態度を高めることが重要であると言える。
5. 一方で、周囲の承認（Subjective norm）と責任感（Locus of control）は、DX 実行意思(DX intention)との間に直接的な影響は少ない。

以上の結果から、DX 実行意思を高めるためには、個々のスキルや能力に対する自信の促進と DX に対する積極的な態度を育成することに焦点を当てることが有効であることが明らかになった。また DX 実行意思と DX3 分類及び DX 結果の間に相関関係を見出すことが

できた。




図 4-7 第二次 DX 実行意思モデルの分析結果

本分析を経て更新したモデルを図 4-8 に示す。太線はパス係数が 0.6 以上、実線はパス係数が 0.4 以上であり 0.6 未満、点線はパス係数が 0.2 以上であり、0.4 未満を現している。




図 4-8 第二次 DX 実行意思モデル

前項で触れた 5 点の目的について振り返る。1 点目は、被験者数を増やしたことで p 値が多く項目で優位水準となり、分析結果の信頼性を確保ができた。2 点目は、DX 分類と DX 実行意思の調査設計を見直した結果、強い正の相関関係を示された。3 点目は、主成分分析により DX 実行意思を構成する因子の設問数を減らしたが、Subjective norm の Chronbach's alpha 値が低かったため、この点について問題がある可能性があるが、他の項目については問題がないことが確認できた。4 点目は、人間機械協働因子の取得と DX 分類との間で強い正の相関関係が確認できた。5 点目は、MLS 深化の設問を追加したが、DX 分類との間に相関関係を認められなかった。

4.4. 一次分析と二次分析の関係

一次分析と二次分析の違いは 5 点あげられる (図 4-9)。1 点目に、一次分析では DX 実行意思 (DX intention) とスキルや能力に関する自信 (Perceived competence) は強い正の相関関係が見られたが、二次分析では、弱い正の相関関係となり弱まった。これは一次分析が DX 研修実施後だったため、スキルや能力に関する自信が DX 実行意思に直結したと解釈できる。

2 点目に、一次分析で DX 実行意思 (DX intention) と周囲の承認 (Subjective norm) は中程度の正の相関関係が見られたが、二次分析では、相関関係が認められなかった。こ

これは一分析の被験者が会社から承認を受けて研修に参加したものであったため、周囲の承認にと DX 実行意思が直結したと解釈できる。

3 点目に、一次分析で DX 実行意思 (DX intention) と DX に対する態度 (Attitude toward DX) は相関関係が認められなかったが、二次分析では、弱い正の相関関係が認められた。

4 点目に一次分析で DX 実行意思 (DX intention) と 責任感 (Locus of control) は弱い負の相関関係が認められたが、二次分析では、相関関係が認められなかった。

5 点目に、一次分析で DX 分類 (DX evolution type) と DX 実行意思 (DX intention) は相関関係が認められなかったが、二次分析では、強い正の相関関係が認められた。これは DX 分類における設問を見直したためといえる。

二次分析での成果は、大きく 2 点ある。1 点目に DX 分類 (DX evolution type) と DX 実行意思 (DX intention) の強い相関関係が認められたことで DX3 分類のステージを切り上げるうえで DX 実行意思が重要とわかったことである。2 点目に DX 分類 (DX evolution type) と人間機械共同協働因子 (HMC factor) のつながりが明らかになった点である。この点については 5 章 6 節 2 項で述べたい。




図 4-9 第一次 DX 実行意思モデルと第二次 DX 実行意思モデルの違い

4.5. 小括

本研究の分析結果から、以下の知見が得られた。第1に、起業意識と企業内でのDX実行意思は類似した特性を持ち、理論の援用が可能であることが立証された。これは、起業意識の理論（田路ら 2016）がDX実行意思の理解と促進に有用であることを示唆している。第2に、DX分類とDX実行意思には強い正の相関関係が認められた。具体的には、3章4節で述べたDX分類のステージを切り上げるためには、DX実行意思が強い影響を与えることが明らかになった。以上の結果は、企業がDXを推進する上で重要な因子と実務的な示唆を示しており、DX実行意思の育成がDX成功の鍵であると結論付けられる。

5. 機械学習応用システムの深化プロセス

本章では MRQ の DX の進化と人間と機械学習応用システムの深化と協働の構成要素である、人間と機械学習応用システムの深化と協働について説明する。DX を実現するうえでビッグデータを利活用できる機械学習応用システムは重要である。機械学習応用システムは技術のみではなく、人間系を含んだシステムであり本章では人間・機械協働の概念を含んだ機械学習応用システムの深化プロセスを取り扱う。この研究の目的は人間・機械協働の概念を含んだ機械学習応用システムを取り扱ってきた企業がどのように深化したかを 15 の事例から機械学習応用システムの深化プロセスの詳細化と人間・機械協働の概念を提案する。

5 章 1 節では機械学習応用システムの深化プロセスを先行研究から論理的にモデリングした結果を示す。5 章 2 節では事例研究の目的と研究方法を示す。5 章 3 節ではテーマティック・アナリシス法による分析結果を示す。5 章 4 節では機械学習応用システムの深化プロセスの各ステップの詳細を示し、それぞれの内容とインタビュー内容で代表的なコメントを記す。5 章 5 節では人間・機械協働の分析と重要な要素の提示を行う。5 章 6 節は機械学習応用システムの深化プロセスの次ステップに至る条件と人間・機械協働における因子を分析する。

5.1. 機械学習応用システムの深化プロセス

本節では、先行研究で議論された深化プロセスについて記述する。基本モデルは Porter and Heppelmann(2014)と Daugherty and Wilson(2018)が重要な先行研究となる。まず初めに機械学習応用システムの深化プロセスと開発プロセスの違い（表 5-1）について述べたい。

開発プロセスは新しい製品やサービスを創造するためのプロセスを指す。目的は新製品や新サービスの開発であり、開始時期はその設計や開発を始める最初の段階からである。アプローチとしては、ビジネスのニーズや問題を特定し、それに対するソリューションの可能性を探索する。目標は製品やサービスの設計、試作、テスト、そしてリリースであり、結果として新しい製品やサービスが完成することである。これらは通常の業務アプリケーションの開発やサービス開発で使われるものである。

深化プロセスは、システムのコンセプト実現のため、コードの再利用を行い新しいシステムを再構築するプロセスである。このプロセスでは、既存のシステムをさらに深化させるために、既存の概念を活かして開発することが重要視される。アプローチは、現在の制約を特定し、それを克服するために既存の機能を拡張または改良し新しいシステムを再構築することであり、主に機械学習を使用して解決する。目標は製品またはサービスの製

品やサービスの新しいバージョンのリリースであり、結果として既存システムを基に新しいシステムに再構築した結果、システムは深化したバージョンが完成する。

製品やサービスを初めて作り出すための「開発プロセス」と、既に存在するものを根本から見直し、改善していく「深化プロセス」という二つの異なるアプローチを比較している。それぞれのプロセスは、特定の目的と戦略を持ち、最終的な目標と成果に向けて展開される。

表 5-1 機械学習応用システムの深化プロセス

	開発プロセス	深化プロセス
目的	新しい製品やサービスを開発	コンセプト実現のために、コードの再利用を行い新しいシステムへ再構築
開始時期	製品やサービスの設計・開発を始め最初の段階から開始	システムを深化させていくためには、既存の概念を活かし拡張することが重要
アプローチ	ビジネスのニーズや問題を特定し、ソリューションの可能性を探求	現在の制約を特定し、それらを克服するために既存の機能を拡張または改良し新しいシステムを再構築する。制約は主に機械学習を使用して解決する
目標	製品やサービスの設計、試作、テスト、リリース	製品やサービスの新しいバージョンのリリース
結果	新しい製品やサービスの完成	既存システムを基に新しいシステムに再構築した結果、システムは深化したバージョンが完成する

次に機械学習応用システムの深化プロセスのモデル（図 5-1）について触れたい。著者は先行研究からモデルを再構成し、機械学習応用システムの深化プロセスのモデルを構築した。




図 5-1 機械学習応用システムの深化プロセス

Capabilities of smart connected products (Porter and Heppelmann 2014) に深化概念が記述されているが、本論文は段階的な深化プロセスが人間・機械協働の機械学習応用システムに適用可能かを明らかにするものである。先行研究では、AI モデル開発のプロセス、一連の技術的特徴、および問題点が明確にされていない。Daugherty and Wilson (2018) は、人間のみの活動と機械のみの活動を分け、それらの間に人間と機械のハイブリッド活動でギャップをミッシングミドルとして定義した。本論文は、Porter and Heppelmann (2014) による smart connected products の構成を参考にしながら、機械学習応用システムに人間・機械協働によるインタラクションを取り入れ考察を行う。Daugherty and Wilson (2018) による「ヒューマン + マシン」に基づいて人間・機械協働に関する視点を含み、機械学習応用システム内の人間と機械の協働の重要性を示している。機械学習応用システムの深化プロセスのプロセスごとの概要を表 5-2 に示した。この研究は、機械学習応用システムの深化パターンのモデルの 4 つの段階の特性を示すために演繹的に行われた。

表 5-2 機械学習応用システムの深化プロセスの特徴

プロセス	概要
可視化	可視化とは、社内情報を取得・可視化し、アクター間の共創により仮説検証サイクルを回すことで要求や仕様を明確にする。
人間中心 ML 補助	機械学習応用システムは、予測、推論、分類、検知を実行する。これらには機械学習応用システムによる判断が一部含まれている。人間は機械学習応用システムからの出力を解釈し翻訳、伝達する
ML 中心人間補助	機械学習応用システムは予測、推論、分類、検知を実行し、その出力は主に業務の運用に使用される。何らかのエラーが発生した場合は人間が対応する。情報の定義を行い、異常系処理を削減する。
自律	前フェーズで定義した情報に基づいて、イレギュラーな処理をほぼゼロにする。

機械学習応用システムの深化プロセスは、人間と機械間の調整プロセスを含む。機械学習応用システムに関わる人間と機械は、それぞれ X 軸に示される人間の関与度と Y 軸に示される ML 関与度において以下のように段階的に人間の仕事を ML に代替することで深化する (図 5-2)。




図 5-2 機械学習応用システムの深化プロセスと人間・機械のモード

機械学習応用システムを実装する際、人間は仮説検証プロセスに関与しており、図 5-2 の右下の象限に示されている（この段階では可視化）。このステップでは機械学習は関与せず、データ量が不足している場合や投資する価値がないタスクでは、後続の人間中心 ML 補助のステップには深化しない。

次に、機械学習への関与度を高め、プロセスは人間中心 ML 補助（図 5-2 の右上の象限）に進む。ここでは、機械学習が必要であり、人間の判断を支援する。この時点では、データの不足やデータ精度に問題があり、機械学習の精度は低い。機械学習応用システムによって出力される価値は、人間による解釈と不規則なケースに対応するため多くの外挿（その範囲外にある値や事象を推定するプロセス）が必要である。ここでは、高リスクのタスクを含む、高度な人間の補助が必要である。一部のタスクは、このステップを最終とする例えば、人間への評価や助言は、人間のインターフェースが望ましく、人間は機械学習応用システムの出力を利用する。

ML 中心人間補助は、図 5-2 の中央に示されている。このステップを開始するためには、人間の関与度を低減させる必要がある。ここでは、機械学習応用システムが意思決定を行い、不規則なケースが発生したときに人間が支援する。このステップの最終タスクは、リスクが低く、データが十分で、人間の解釈が必要ないものである。言い換えれば、このステップではシステムの成熟とユーザーに信頼されるシステムが必要である。機械学習応用システムのビジネス利用は、機械はもとより活用する人間側も成熟した段階にある必要がある。


自律は、システムが人間の関与なしに機械学習応用システムの判断のみで運用される状態である（図 5-2、左上）。このレベルでオフィスシステムを運用できるケースは少ない。このレベルでは、十分にリスクフリーであるべきである。ここでは、データとシステムの成熟が必要であり、人間との調整は原則不要となる。

5.2. 事例研究の目的と研究方法

機械学習を実装した事例研究のケースは多数あるが、機械学習応用システムが深化した事例研究のケースは比較的少ない。この研究は、事例研究によって複数の事例を分析することで機械学習応用システムの深化プロセスモデルの検証と詳細化及び深化プロセスごとの人間・機械協働の特徴を明らかにすることが目的である。

3 章 3 節でも記述したように、インタビュー対象者のサンプリングにおいて質的研究という手法はサンプリングにおけるサンプリングバイアス、代表性の確保、サンプルサイズの適切さ、一般化の確保といった問題がある。サンプリングバイアスにおいては筆者の人間関係から便宜的サンプリングを行い、その関係からスノーボールサンプリングを行った。そのため一定のバイアスがかかっている可能性がある。代表性の確保においてはバリューチェーンの主活動に限定し、機械学習応用システムの選定を行った。業界をなるべく分散するように意識した。次の段落で詳細を記述する。サンプルサイズの妥当性については理論的飽和が観察できたため 15 件のサンプルで分析を行った。一般化の確保は機械学習応用システムに取り組んでいる企業に限定してデータコレクションを行っており、範囲を限定したことで解決をしている。

インタビュー対象者は、図 5-3 に示されるバリューチェーン (Porter 1985) の主活動 (Primary Activities) で機械学習応用システムを取り扱う DX 推進部門の日本企業のマネージャーや CXO である。主活動は購買物流 (Inbound logistics)、製造 (Operations)、出荷物流 (Outband logistics)、マーケティング・セールス (Marketing, Sales)、サービス (Service) を分析対象とした。Support Activities (支援活動) にはインフラ (Firm Infrastructure)、人事 (Human Resource Management)、技術 (Technology Development)、購買 (Procurement) 等が入るがこの領域はパッケージソフトウェアや SaaS が介入することが多く、対象からは除外した。ユーザー部門はインタビューを実施しておらず、インタビュー対象者は企業変革の側に立つ人物である。



(Porter 1985 に加筆)

図 5-3 事例研究対象プロジェクトの位置付け


15 名のインタビュー対象者へ半構造化インタビューを実施し、データを収集した（表 5-3）。インタビューアプローチの利点は、インタビュー対象者から多様な視点を集められる点にある。これらのインタビュー対象者は、機械学習応用システムを活用した DX をリードしている企業を選定している。

結果の妥当性について記述したい。データコレクションと分析においては、複数のデータソースを用いて信頼性を確保した。インタビューをテキストに書き起こし、質的データ分析ソフトウェアを使用してコーディングを実施した。コーディングプロセスの信頼性を高めるために、ほかの研究者によるレビューを受け、結果の信頼性と妥当性を担保した。また、得られた結果を専門家によるレビューをしてもらい、確認するプロセスを取り入れた。これにより、研究の信頼性と妥当性を高めた。

表 5-3 インタビュー対象者

インタビュー対象者 ID	プロジェクト	業界	バリューチェーン	部門
インタビュー対象者 1	プロジェクトエラー予測システム	電気機器製造業	オペレーション	ソフトウェア エンジニアリング部
インタビュー対象者 2	自動販売機巡回計画システム	飲料製造業	出荷物流	AI/DX 事業部
インタビュー対象者 3	MR 日報分類システム	医薬品製造業	セールスマーケティング	AI/DX 事業部
インタビュー対象者 4	デジタルマーケティングシステム	自動車製造業	サービス	デジタルイノベーション 推進部
インタビュー対象者 5	所持品認識システム	医療・福祉業	サービス	デジタルイノベーション グループ
インタビュー対象者 6	インターネット広告最適化システム	広告業	セールスマーケティング	新規事業開発部
インタビュー対象者 7	販売計画システム	広告業	サービス	IT 戦略部
インタビュー対象者 8	家賃利回り計算システム	不動産業	サービス	CEO、CTO
インタビュー対象者 9	在庫配分最適化システム	情報通信業	出荷物流	CDx0
インタビュー対象者 10	侵入検知および防御システム	情報通信業	オペレーション	研究開発部
インタビュー対象者 11	広告配信システム	広告業	サービス	AI 事業部
インタビュー対象者 12	e コマースレコメンドシステム	情報通信業	サービス	CTO
インタビュー対象者 13	売上評価システム	金融業	セールスマーケティング	デジタルイノベーション部
インタビュー対象者 14	類似事業見積りシステム	建設業	セールスマーケティング	デジタルイノベーション部
インタビュー対象者 15	ひび割れ検出システム	不動産業	インバウンド物流	DX 推進部

著者は、内平ほか（2019）による文献と複数のインタビューから作成された QAML プロジェクトのニーズマップ・技術的シーズ・施策（図 5-4）を再構築して設問表を作成し、半構造化インタビューを実施した。表 5-4 にインタビュー質問が示されている。インタビューは、アルゴリズムの選択、AI モデル更新判定基準など、機械学習応用システムと技術的決定を検証するための追加質問も行った。



（内平ほか 2019 に加筆）

図 5-4 QAML ニーズマップ・技術的シーズ・施策

表 5-4 インタビュー設問表

No.	質問のカテゴリ	質問例
1	機械学習応用システムのプロジェクト	機械学習応用システムの詳細は？
2		機械学習応用システムの要求は具体的だったか？
3		機械学習応用システムの仕様は具体的だったか？
4	プロジェクトに関与するアクター	主なアクターと役割は何か？
5		機械学習応用システムリリースの妨げとなるアクターはいるか？
6	困難と解決策	データの取得と前処理における問題は何か？解決策はあるか？
7		モデルの構築、評価、監視における課題は何か？解決策はあるか？
8		機械学習応用システムに倫理的な問題はあるか？（プライバシー、セキュリティ、人的作業、リスク対策、公平性、ユーザー理解、法制度） 解決策はあるか？
9		機械学習アプリケーションシステム全般における困難はあるか？ 解決策はあるか？（AI 理解、人材、開発、安全、品質保証など）

Amershi ら(2019) は、機械学習応用システムに関わる Microsoft の 14 人のソフトウェアエンジニアに半構造化インタビューを実施し、551 人のソフトウェアエンジニアへの定量的分析を実施した。McIntosh and Morse (2015)によると、「半構造化インタビューは、研究トピックに関連する経験について参加者の視点を確認する」ものである。この研究の研究質問に答えるためには、機械学習応用システムに関わるユーザーの視点を広く分類する必要があり、著者らはこの研究方法が適切であると判断した。インタビューは 60～90 分間日本語で行われ、記録およびトランスクリプトへの書き起こしを実施した。

この研究では、質的および定量的分析を実施した。コンピュータ支援質的データ分析 (CAQDA) により、研究者は文脈を把握し分析することができる。定量分析は MAXQDA (バージョン 22.1) ソフトウェアを用いて実施された。

質的データを分析するためにテーマティック・アナリシス法を使用した。この技術は、質的データ内のパターンを見つけるための体系的プロセスである (Boyatzis 1998)。テーマ分析には、演繹的、帰納的、およびハイブリッドのアプローチがある (Fereday and Muir-Cochrane 2006)。この研究で使用されたハイブリッドアプローチは、演繹的および帰納的アプローチの両方を利用する。まず、演繹的アプローチは 5 章 1 節で定義されたモデルを検証するために使用された。次に、帰納的アプローチは、特徴や課題を明らかにするといったモデルの洗練のために使用された。

研究方法論の流れを図 5-5 に図示した。まず、著者は関連する先行研究を調査した。キーワードはソフトウェア工学、機械学習工学、機械学習応用システムのプロジェクトマネジメント、人間・機械協働、およびシステム深化に基づくものである。次に、半構造化インタビューを実施し、テーマ分析を用いた CAQDA を用いた定性分析を実施した。最後に、対応するモデルを洗練し最終的なモデル導出を行った。




図 5-5 研究の流れ

5.3. テーマティック・アナリシス法による分析結果

分析方法はテーマティック・アナリシス法に基づいており、二つの段階を経ている。第 1 に、演繹法によるモデルバリデーションの実施である。これにより、機械学習応用システムの深化プロセス（4 ステップ）を先行研究の文脈に基づいて明らかにした。第 2 に、15 のインタビュー対象者を基に、機械学習応用システムの深化プロセス（4 ステップ）の特徴と困難を帰納的に詳細化した。

Capabilities of smart connected products (Porter and Heppelmann 2014) ではスマートコネクテッド製品の技術的特性を明らかにした。ただし本研究では人間系を含む機械学習応用システムの深化概念の取り扱いはない。本研究では、この研究の範囲の拡大に向けて、Daugherty and Wilson (2018) の「ヒューマン+マシーン」に基づく人間・機械協働に関する視点を含め、機械学習応用システムの深化プロセス内での人間・機械協働の重要性を分析した。上記の通り、機械学習応用システムの深化と人間・機械協働との相互作用に関する包括的分析を通じて、機械学習応用システムの深化プロセスの 4 ステップを導出した。これはステップ 1：可視化、ステップ 2：人間中心 ML 補助、ステップ 3：ML 中心人間補助、ステップ 4：自律の特徴を有する。インタビュー対象者の事例を機械学習応用システムの 4 ステップの深化プロセスに分類した。表 5-5 に事例研究対象プロジェクトに深化プロセスを対応させたものをまとめた。

表 5-5 事例研究対象プロジェクトの深化プロセス

深化プロセス	インタビュー対象者
可視化	4, 5
人間中心 ML 補助	1, 3, 6, 7, 10, 13, 14
ML 中心人間補助	2, 8, 15
自律	9, 11, 12

次に、15 名のインタビュー対象者の情報を基に、機械学習応用システムの深化プロセス（4 ステップ）の特徴と困難を帰納的に詳細化した。機械学習応用システムの深化プロセスは、人間・機械協働を含む機械学習応用システムの深化プロセスを表している。本研究では、機械学習応用システムの発展において人間・機械協働の重要性に着目し、人間の介入が如何にシステムの有効性を高めるかを示している。表 5-6 は機械学習応用システムの深化に関する 4 つのステップの特徴と困難を示している。またそれぞれのステップにおける特徴と困難を導出するために参照したインタビュー対象者のコメント ID が関連付け

られている。右側の列は、これらのプロセスステップに対応するインタビュー対象者のコメント ID を示しており、インタビュー対象者がどのような意見や経験を提供したのかを示すリファレンスとして機能している。例えば、可視化プロセスにおけるデータ結合手法についてはインタビュー対象者のコメント ID 4-1 及び ID5-1 で特徴と困難を導出している。

表 5-6 機械学習応用システムの深化プロセスの特徴と困難のソース対応表

深化プロセス	特徴と困難	ソース
可視化	データ結合プロセス	インタビュー対象者 4-1, インタビュー対象者 5-1
	仮説検証プロセス	インタビュー対象者 4-2, インタビュー対象者 5-2
	ユーザーとの共創	インタビュー対象者 2-1, インタビュー対象者 7-1, インタビュー対象者 13-1
人間中心 ML 補助	過度に高い AI への期待値	インタビュー対象者 6-1, インタビュー対象者 6-2, インタビュー対象者 10-1
	AI の活用困難性	インタビュー対象者 2-2, インタビュー対象者 3-1, インタビュー対象者 13-2
	積極的な人間の介入	インタビュー対象者 2-3, インタビュー対象者 3-2, インタビュー対象者 11-1
ML 中心 人間補助	パイプラインジャングルとデータエンジニアリングの難しさ	インタビュー対象者 9-1, インタビュー対象者 12-1
	システムの成熟	インタビュー対象者 1-1, インタビュー対象者 2-4, インタビュー対象者 2-5, インタビュー対象者 9-2
	ユーザーとの信頼	インタビュー対象者 2-6, インタビュー対象者 8-1, インタビュー対象者 12-2
自律	異常系処理の難しさ	インタビュー対象者 10-2, インタビュー対象者 11-2, インタビュー対象者 12-3
	データ駆動型オペレーション	インタビュー対象者 9-3, インタビュー対象者 11-3

5. 4. 機械学習応用システムの深化プロセスの特徴と困難

人間系を含む機械学習応用システムの深化プロセスは図 5-1 に示した。これには 4 つのステップがあり、ステップ 1：可視化；ステップ 2：人間中心 ML 補助；ステップ 3：ML 中心人間補助；ステップ 4：自律である。。AI 実装プロセスはステップ 2（人間中心 ML 補助）とステップ 3（ML 中心人間補助）の 2 つのステップに分けられている。また、人間系のシステムと機械系のシステムは異なるモードを表し、どの方法が中心かによってステッ

プが異なる。

表 5-6 にまとめたソースを基に、特徴と課題を図 5-6 にまとめた。ステップ 1：可視化 (Visualization)では、データ結合プロセス、仮説検証、ユーザーとの共創が重要である。ステップ 2：人間中心 ML 補助 (Human-centered ML assistance)では、過度に高い AI への期待値、AI の活用困難性、積極的な人間の介入といった特徴がみられる。ユーザーの理解と活用促進するために機械学習応用システムをユーザー中心で試行錯誤を繰り返す時期であり人間系・機械系の双方の成熟途上の段階である。ステップ 3：ML 中心人間補助 (ML-centered Human assistance)では、機械学習が中心となり判断を実施する。ただし、エラー時など不測な事態の際は人間がサポートする。パイプラインジャングルとデータエンジニアリングの難しさ、システムの成熟、ユーザーとの信頼といった特徴がみられる。パイプライン最適化、エラー解決範囲の拡大などシステムの継続的な改善が必要であり、同時にユーザーが機械学習応用システムを信頼してもらうためにも十分なコミュニケーションが必要とされる。ステップ 4：自律 (Autonomy)では、システムは高い自律性を有しており、エラーを限りなく最小化し、耐障害性が優れている状態である。異常系処理の難しさ、データ駆動型オペレーションといった特徴がみられる。自己診断と自己修復機能により、システムのダウンタイムが最小限に抑え、ビジネスの連続性が保たれる。また、データ駆動型のオペレーションが行われ、データ品質の管理、予測値の妥当性の検証が定期的




図 5-6 機械学習応用システムの特徴と困難

5.4.1. 可視化

ステップ 1 の可視化では、ユーザーからの情報を人間が理解できるよう視覚化される

状態を指す。この視覚化により、状況を理解し問題を特定することができる。可視化にはデータが必要だが、企業内部からデータを収集し処理することはしばしば困難である。可視化のためにはデータソースの特定、データ統合処理などの前処理が必要となる。これらを解決するために Google Cloud Platform (GCP)、Amazon Web Services(AWS)、Microsoft Azure などのデジタルプラットフォームにデータを統合することが一般的である。ただし、データ量が少なければ、Microsoft Excel や Access を使用して開始することも可能である。

可視化は、アクターとの共創を通じて仮説検証サイクルを回すことで要件と仕様を明確にする。本研究では可視化のステップで 3 つの特徴と困難を見出した。第一はデータ結合プロセスに関連する困難性、第二は仮説検証プロセス、第三はユーザーとの共創である。第一のデータ結合プロセスでは、社内データとオープンデータは構造化データと非構造化データに分けられ両方のデータを対象とする。社内データ及びオープンデータをデータウェアハウスに保存する前に、抽出、変換、およびロード (ETL) プロセスが必要である。非構造化データは必要に応じてソフトウェア処理により、構造化データされる。データソースの特定、データ抽出、データ変換、構造化データとしてデータウェアハウスやデジタルプラットフォームへの保存という処理となる。仮説検証プロセスは、データを何に使うかを明確にする。その後段階的に深化プロセスに定義されているステップを踏む。可視化が目標であれば、このステップが最終ステップになるが、機械学習応用システムは通常、このステップを超えて進む。

(1) データ結合プロセス

データ結合プロセスは始めデータ収集プロセスが存在する。このプロセスには、社内およびオープンデータを組み合わせてデジタルプラットフォームやデータウェアハウスに保存する作業が含まれる。様々なデータタイプを統合するプロセスは複雑であり、しばしばデータ品質の問題や、データの不整合に関連する問題を含む。したがって、データ結合プロセスを効果的に実行するためには、データ品質の改善と正確なデータ収集プロセスを確保に焦点を当てることが重要である。

「ビッグデータ分析をするためのシステムがなかったため、大規模データに対する機械学習処理を行うのは容易ではなかった。GCP に集約した後、BigQuery でデータを処理し、その後 Python で AI モデルの開発を行った。」(インタビュー対象者 5-1)

「オンラインデータとオフラインデータを組み合わせるのは困難である。集約、可視化、要約、再び可視化を繰り返し、データ利用を想像しながらプロセスをすすめた。このプロセスを自動化することは役立つが、現実にはマーケティングに

精通したデータサイエンティストが必要だ。」(インタビュー対象者 4-1)

(2) 仮説検証プロセス

仮説検証プロセスは、データの可視化を通じてデータの意味と特性を理解し、効果的に問題解決を促進するために必要な情報を抽出することで行われる。ここで重要なのは、仮説を設定し、その仮説が支持されるかどうかを検証するためにデータを分析することである。仮説検証プロセスは、ビジネスの問題を解決するための効果的な解決策を決定することに役立つ。

「MLS を使いながらデータの可視化を試みている。」(インタビュー対象者 4-2)

「(ユーザーである) マーケティング担当者もデータサイエンティストもアウトプット定義がイメージできない中、アウトプットを評価しながら開発を進めた。ユーザーとの理解を深め合意に至るには 1 か月かかり、毎日可視化に基づいて議論を行った。」(インタビュー対象者 5-2)

(3) ユーザーとの共創

ユーザーとの共創は、可視化ステップでユーザーと協力してビジネスの問題を解決することを指す。ここでは、ユーザーが直面している問題に関する情報を収集し、可視化を行い共同で仮説を検証し、協力的な方法で効果的な解決策を見定めることが重要である。ユーザーは、関連するニーズや課題を最もよく理解しているため、ユーザーと協力して解決策を練ることは、ビジネスの問題を効果的に解決するために不可欠である。

「要求が具体的でないとき、データを (BI システムに) 投入して視覚化された画面でさまざまなことができると感じた。」(インタビュー対象者 7-1)

「分類の際に視覚化を使用した。」(インタビュー対象者 13-1)

「機械の判断が正しいことを証明するために視覚化を行った。」(インタビュー対象者 2-1)

5.4.2. 人間中心 ML 補助

ステップ 2 における人間中心 ML 補助は、機械学習のモデルによる予測、推論、分類、検知などの機械学習固有の所作が含まれる。機械学習応用システムのモデルに基づいた出力を、人間のアクターが取得し情報に基づいて意思決定を行う状態を指す。この段階においては、人間は機械学習応用システムの出力を基に判断の妥当性を検証しなければならない。機械学習応用システムによる判断の誤りによるリスクの大きさや、異常ケースの数によっては人間の判断が都度要求されることもある。本稿ではこのフェーズにおける 3 つの特徴を次のように定義した。1 点目は、過度に高い AI への期待値、2 点目は AI の活用困難性、3 点目は積極的な人間の介入である。ユーザーは機械学習応用システムに高い期待を持っている。ユーザーの要求は具体的であるが、仕様が不明確である。そのため、ユーザーの期待値を管理し、アジャイルな開発を進めることが重要である。機械学習応用システムの利用には多くの困難が伴う。例えば、機械学習応用システムの価値を全てのユーザーが理解しにくい、ユーザー側には機械学習応用システムの翻訳者が必要である。人間は機械学習応用システムの出力に基づいて解釈を行い、ユーザーの誤解を避けるために積極的な人間の介入が必要である。

(1) 過度に高い AI への期待値

ユーザーが AI に対して持つ過度に高い期待値と実現可能性の低い要求を指す。ユーザーは機械学習技術に精通しているわけではなく、機械学習応用システムの上位概念として本論文では定義している AI に対して過度な期待を持ちがちである。これは機械学習への無理解と機械学習の活用の経験不足によるものである。機械学習応用システムの価値を完全に理解するのは苦勞が伴う。したがって、ユーザーの期待値を管理し、過度な期待値についてはすり合わせ過程で調整をかけるべきである。また、ユーザーが機械学習応用システムを効果的に利用できるように支援することが重要である。

「顧客から使えるものとは言われていたが、具体的な数字は示されていなかった。ユーザーは精度を参考にしか見ていない。顧客は使ってみて感覚的な間違いの数で評価する。」(インタビュー対象者 6-1)

「AI の理解があまりなかったので、期待値が過剰であった。」(インタビュー対象者 6-2)

「精度に対する厳しい要求があったが、すり合わせ過程でバー(基準)は下がっ

た。AI は誤りをしてはならないと主張する者が多い。」(インタビュー対象者 10-1)

(2) AI の活用困難性

AI の活用困難性とは、ユーザーが機械学習応用システムを効果的に活用しようとする際に直面する挑戦を指す。ユーザーはしばしば機械学習応用システムの価値や効果的な使用方法を完全に理解することができない。そのためユーザーが使ってくれない、このシステムは使えないという決めつけがときに発生する。精度に関する科学的な指摘ではなく、感覚的な拒否が多い。これらを解決するために専門的なサポートが必要である。

「ユーザーは AI に大きな関心を示している。しかし、使い始めたばかりであり、利用率を把握する段階である。」(インタビュー対象者 13-2)

「ブロッカーになる人は営業所ではいたが、企画の人が説得してくれたのであまり感じなかった。反対する理由は、自分たちは他とは違う、お客さんの影響が強いなど自分たちは特別であるという主張が多かった。これは統制されたくないという気持ちの表れかと思われる。」(インタビュー対象者 2-2)

「AI が 10%間違っているユーザーは反発する。これは将来的な課題である。」(インタビュー対象者 3-1)

(3) 積極的な人間の介入

積極的な人間の介入とは、機械学習応用システムによって出力された情報を人間が自身の知識や経験を適用しながら解釈し、ユーザーによる誤解を避けることを指す。AI の活用困難性でも述べたようにユーザーは決して機械学習に詳しいわけではない。そのため、積極的な人間による介入を行うことで誤解を避け、過度な期待値や思い込みを随時修正することが重要である。積極的に介入する能力は、機械学習応用システムと協働するユーザーにとって重要なスキルである。

「(日報の分類における) 仕様を確定する際の課題は、分類の評価方法である。それが正しいかどうか (ユーザー部門に確認をしながら)、そしてどのように精度を向上させるかについて悩むことが多かった。」(インタビュー対象者 3-2)

「人間の仕事を支援するシステムであるため、システムの出力値の解釈は人間によって行われる。」（インタビュー対象者 2-3）

「ユーザーとしては、顧客に理解させるのが難しかった。」（インタビュー対象者 11-1）

5.4.3. ML 中心人間補助

ステップ 3：ML 中心人間補助では、ステップ 2：人間中心 ML 補助を通してユーザーが機械学習応用システムを一定程度信頼し、活用している状態で成り立つ。ここでの主要な特徴及び課題は、イレギュラーケースにおける自動処理率の向上に関連している。特に、機械学習を用いて自動化の領域を拡張することに重点が置かれる。

この段階で 3 つの特徴及び課題を発見した。1 点目はパイプラインジャングルとデータエンジニアリングの難しさ、2 点目はシステムの成熟、3 点目はユーザーとの信頼である。1 点目のパイプラインジャングルとデータエンジニアリングの難しさは、ビジネスプロセスの難しさとデータフローの複雑さから、パイプラインジャングルの問題が発生する。ここでいうパイプラインジャングルとは、新しいデータソースの追加に伴い、データ処理のパイプラインが増加し、管理が難しくなる現象を指す。2 点目はシステムの成熟である。システムの成熟とは、機械学習応用システムをビジネスプロセスに完全に統合し、意思決定プロセスを主導できるレベルまで深化することを指す。ここではシステムの精度と信頼性を高め、意思決定における人間の介入を減らすことを目指す。3 点目のユーザーとの信頼は、機械学習応用システムがビジネス環境で正確に機能することを保証し、その出力の妥当性をユーザーに説明し納得をしてもらうことである。この過程で、データの可視化やロジックの開示を通じて、システムの判断が正しいことを証明し、ユーザーからの支持を獲得する。

インタビュー対象者 9 のように、ビジネスシステムがすでにデータ駆動型管理に基づいている場合、デジタル化前の企業よりも困難は少ない。ビジネスシステムがデジタル化前の段階にある場合、対応する機械学習応用システムと人間の成熟には時間が必要である。言い換えれば、機械学習応用システムの成熟には、機械学習応用システム自体の成熟だけでなく、ユーザーの成熟も必要である。これには、人間の作業を減らし、ユーザーが機械学習応用システムを信頼するまで時間とコストをかけていく必要がある。パイプラインジャングルとデータエンジニアリングの困難に直面した際は、機械学習応用システムを含めたビジネスシステムを再設計する必要がある。

(1) パイプラインジャングルとデータエンジニアリングの難しさ

パイプラインジャングルとは、複数のデータソースからの大量のデータを扱う際にデータパイプラインで生じる複雑さと混乱を指す。これにより、データ処理のためのパイプラインを効果的に管理し最適化することが難しくなり、処理時間の増加や効率の低下につながる可能性がある。データエンジニアリングの困難とは、大量のデータを処理、保存、分析するために必要なインフラストラクチャを設計、実装、維持することに関連する課題を指す。ここでは、これらの課題に対処し、データ駆動型ビジネスプロセスを構築するために、慎重な管理とインフラストラクチャの最適化が必要である。

「データ取得自体に問題はない。なぜなら、データはよく構造化されたデータウェアハウスにあるからだ。説明変数を増やすために、ノイズ削減とクレンジングが必要だった。データの断片化は起こっていない。ビジネスプロセスはデータに基づいて運営されている。開発テストでは、パイプラインジャングルがある。データを蓄積するプロセスでジャングルになる。」（インタビュー対象者 9-1）

「ETL 後に Airflow によるフロー処理を行った。ここに運用上の問題がある。IN 側が変わるという問題もあり、パイプラインが的確に動くわけでもない。想定しないエラー、データの整合性がとれなくなる。論理的な部分もあれば、動かしたらパンク（データ量が多くてパンク）することもある。エンジニアリング的な苦労は多い。」（インタビュー対象者 12-1）

(2) システムの成熟

システムの成熟とは、機械学習応用システムをビジネスプロセスに完全に統合し、意思決定プロセスを主導できるまで深化することを指す。システムの成熟は、意思決定プロセスにおける人間の介入の必要性を減らし、対応する機械学習応用システムの精度と信頼性を向上させる。システムの成熟を実現するには、機械学習応用システムが最適に機能し、意図した利益をもたらすように、継続的な監視、評価、および微調整のプロセスが必要である。

「物流（計画を機械学習により最適化すること）に関しては現場が反対することがない。なぜならばデータを基にして物流が動いているためである。計画系で人系オペレーションが存在しない。人ではやりきれないスケールの仕事である。人がやっていた業務を切り替えると問題が起きるであろう。機械でやってほしいと

いう意志が強い」(インタビュー対象者 9-2)

「機械主導でプロジェクトマネジメントは未来の話になる。最適化をするためには調整的な業務が発生する。人と人とのインタラクションが入る。そこを機械が代替するためには、パーソナライズ、説明可能性が必要になってくる」(インタビュー対象者 1-1)

「運用時、稼働直後変な値が出ることがあったので都度バグ対応した。現場の感覚で指摘が入る。顧客の期待値が高い。ここがこなれてくると、システム側が正しいという状態になる。1、2 年くらいかかった。現場になじむまでにはこれくらい時間かかる。信用を得るためにはそれなりに時間がかかる。」(インタビュー対象者 2-4)

「顧客は動いてくれればよい。ロバスト性を意識した。エラーを起こしても、業務が回ることを意識。ロバスト性確保の上での課題は欠損値・異常値対策、データが少なくても回るようにすること。(ビジネス自体は停止を許されないため、システムの堅牢性を意識し欠損値・異常値、データが少なくても結果を返すこととした。正確性を犠牲にしても堅牢性を確保した。)」(インタビュー対象者 2-5)

(3) ユーザーとの信頼

ユーザーとの信頼とは、機械学習応用システムの出力の妥当性をユーザーに説明し、彼らの理解と信頼を得て、ビジネス環境でシステムが正確に機能することを保証することを指す。信頼を築くためには、ユーザーはシステムがどのように機能し、出力結果がどのように得られるかを理解することが不可欠である。したがって、公平性やバイアスなど、様々な関連問題を考慮しながら、ユーザーが理解しやすい方法で機械学習応用システムの出力を説明することが必要である。

「機械の判断が正しいことを証明するためにデータを可視化した。それにより、現場からの支持を得ることにつながる。」(インタビュー対象者 2-6)

「出力をどう解釈するか、そこを納得させるためにロジックの開示とアカデミック活用をしている。」(インタビュー対象者 8-1)

「情報推薦(レコメンドロジック)には偏った推薦が起こりえる。公平性は問

題ではないが、将来的な考慮事項である。」(インタビュー対象者 12-2)

5.4.4. 自律

ステップ 4 自律は、今回研究対象としたオフィスシステムでは頻繁には観察されない。パフォーマンス向上やシステム異常検知及び自動修復には自動処理プログラムが必要である。

人間系を含む機械学習応用システムでは、自律性の範囲は人間にまで拡張される。本段階で 2 つの特徴及び課題を定義した。1 点目は異常系処理の難しさ、2 点目はデータ駆動型オペレーションである。1 点目の特徴及び課題はイレギュラーケース対応の困難に関連している。イレギュラーケースが発生した際に、ステップ 2、3 では人間が解決するがその自動化率を高めることが自律ステップに進む上では重要である。2 点目の特徴及び課題はデータ駆動型オペレーションに関連している。ウェブシステムのログや物流システムにおけるレコードは大量であり、人間による管理は困難である。この場合、人間の介入を必要としないように設計し、オペレーションはデータ駆動型で実施される。データ駆動型オペレーションは自律的に行われる。機械学習応用システムの判断の説明可能性を確保することにより人間を説得する能力を持つことが有用であり、説明可能な AI (Explainable AI) の技術が待たれる。

(1) 異常系処理の難しさ

異常系処理の難しさとは、機械学習応用システムが異常な値を出力した際に人間が問題を解決しなければならないという状態を指す。ここでの人間系によるイレギュラーケースの課題対応は、機械学習応用システムの自律性を高める大きな障害である。

「逐次学習も機能としてはあるが、*AUTO* にするのは大変。」(インタビュー対象者 10-2)

「システム出力値が異常値である場合、人間が問題を解決しています。これを自動的に解決したいのですが、方法が見えてきません。」(インタビュー対象者 11-2)

「大量のデータはパイプラインを詰まらせます。パイプラインが複雑であるため、これを簡素化することが重要です。しかし、仕様がないため難しいです。」(インタビュー対象者 12-3)

(2) データ駆動型オペレーション

データ駆動型操作とは、オペレーションプロセスとビジネスの最適化や管理にあたってデータ駆動型アプローチに基づいて実践を行うことを指す。例えば、インタビュー対象者 9-3 の場合、在庫最適化のタスクはその扱うデータ量の多さにより、人間のスケールでは達成不可能であり、データ駆動型オペレーションが前提となる。インタビュー対象者 11-3 の場合、広告を見て実地に訪問した顧客数の正確な数が不明なため、説明に機械学習を用いた理論値を使用することが前提となる。

「物流（計画を機械学習により最適化すること）に関しては現場が反対することはない。—中略—

人ではやりきれないスケールの仕事である。」（インタビュー対象者 9-3）

「広告を見た正確な訪問者数は誰にもわかりません。そのため、理論値のみを説明します。」（インタビュー対象者 11-3）

5.4.5. 他アクターの役割

ユーザーや DX 推進部門に加えて、経営陣や情報システム部門にも考慮する必要がある。経営陣の意思決定はプロジェクトを推進する力になるものの、プロジェクトを進行するためには委任が必要である。インタビュー対象者 13 と 14 は経営陣がプロジェクトを推進すると述べているが、インタビュー対象者 1 は、経営陣がプロジェクトをあまりにも積極的に推進すると、ユーザー側が躊躇し、機械学習応用システムの受け入れを拒否する可能性があるとして述べている。機械学習応用システムを現場に適応させるためには、DX 推進部門などの別の主体が必要である。情報システム部門は会社のデータを保護する責任があり、DX プロジェクトの開発と受け入れを妨げる可能性がある。しかし、会社のデータセキュリティ規制と機械学習応用システムを統合させる必要があるため、推進にあたって体制を確保し、役割を定義することが重要である。

(1) 経営陣

「社長のトップダウンが入ると、ユーザーは積極的に動きます。経営陣が推進するきっかけは、会社内にミスや苦情がある場合や、同業他社が同じことをしてい

る場合です。」(インタビュー対象者 13-3)

「マネジメントに寄りすぎると、現場から支持を得られない。」(インタビュー対象者 1-2)

「上長からはいつまでこのプロジェクトをやっているのという話はあった。(担当部門長が)ブロックしていた。上長は技術がわかるわけではなく、プロジェクトのうたい文句もしっかりあったので権限を渡してもらっていた。」(インタビュー対象者 15-1)

(2) 情報システム部門

「データ解析プロジェクトでシステム担当がハードルになりえることは多かった。セキュリティ面。データの利用範囲、プライバシーポリシー順守。」(インタビュー対象者 5-3)

「ブレーキを踏むのは情報システム部門。管理しているシステムの枠外のことをやらないでほしい。セキュリティリスクについて主張がある。私たちは説得とすり合わせを繰り返しました。」(インタビュー対象者 14-3)

5.5. 人間・機械協働

機械学習応用システムの深化プロセスは人間・機械協働の特徴を有している。これは人間系と機械系が連動して完全なシステムとして機能する。相互に適応する双方向のプロセスである。機械学習技術はコンポーネントの集合体であり、機械学習応用システムが運用される際には人間がシステムに適応する必要がある。スマートコネクテッドプロダクト (Porter and Heppelmann 2014) では、機械学習応用システムが監視し決定を下す。ただし、人間系はプロセスに存在しないため、スマートコネクテッドプロダクトの各プロセスで人間・機械の協働作業は行われない。機械学習応用システムが人間系のシステムを含む場合、意思決定プロセスは機械系と人間系の両方のモードで実行される。機械学習応用システムは深化プロセスで必ずしも自律を目指すわけではなく、与えられたシステムが扱うタスクによって終点は異なる。

図 5-7 に機械学習応用システムの深化プロセスのステージ別のコード出現率を示した。




図 5-7 機械学習応用システムの深化プロセスのステージ別のコード出現率

ステップ 1 可視化には機械モードがないため、人間・機械協働は存在しない。このプロセスでは、チームが機械学習応用システムへの要求を整理し、効果的に利用する方法を模索している段階である。ステップ 2 は、AI 実装の初期段階である人間中心 ML 補助である。ここでは、ユーザーへトレーニングデータの収集と機械学習応用システムの利用に関与させる努力が行われる。ユーザーの反応に迅速に対応するためにアジャイルな開発が行われる。機械学習応用システムの未熟さのため、ユーザーは機械学習応用システムの解釈が必要でありここで人間・機械協働が認められる。ステップ 3 では、ML 中心人間補助であり、機械学習応用システムへの信頼が増さなければいけない段階である。ユーザーの信頼が低い機械学習応用システムは使ってもらえないため、人間・機械協働のうち機械学習応用システムの出力を解釈し翻訳する作業が最も活発になるステップでもある。機械は成熟しており、機械学習応用システムを使用する人間はよく訓練されている。しかし、異常が発生した場合には、人間が問題を解決する必要がある。このモードの変更は人間によって行われ、人間系を含む機械学習応用システムのパフォーマンスを向上させるためには不可欠である。ステップ 4 自律では、機械学習応用システムが扱う処理はデータ駆動型オペレーションに根差している。これは、データが大量で人間は迅速に結論を出すことが困難なためである。

図 5-7 のソースを表 5-7 及び表 5-8 に示した。人間・機械協働のコードを機械学習応用システムの深化プロセスと対比して作成した

表 5-7 人間・機械協働のソース対応表

深化プロセス	人間・機械協働コード	ソース
可視化	ユーザーの感覚に合わせる(1)	インタビュー対象者 5-4
	ユーザー参画への努力(1)	インタビュー対象者 2-7
人間中心 ML 補助	ユーザーの感覚に合わせる(4)	インタビュー対象者 1-3, インタビュー対象者 1-4, インタビュー対象者 6-3, インタビュー対象者 10-3
	ユーザー参画への努力(9)	インタビュー対象者 3-3, インタビュー対象者 3-4, インタビュー対象者 4-3, インタビュー対象者 10-3, インタビュー対象者 10-4, インタビュー対象者 13-4, インタビュー対象者 13-5, インタビュー対象者 13-6, インタビュー対象者 13-7
	MLS 出力の人間による翻訳(3)	インタビュー対象者 1-4, インタビュー対象者 2-8, インタビュー対象者 3-5
	MLS への信頼(3)	インタビュー対象者 1-4, インタビュー対象者 14-4, インタビュー対象者 14-5
	MLS への不信(3)	インタビュー対象者 3-5, インタビュー対象者 13-8, インタビュー対象者 14-6
ML 中心 人間 補助	ユーザーの感覚に合わせる(2)	インタビュー対象者 2-9, インタビュー対象者 2-10, インタビュー対象者 6-4
	ユーザー参画への努力(3)	インタビュー対象者 2-10, インタビュー対象者 8-2, インタビュー対象者 8-3
	MLS 出力の人間による翻訳(4)	インタビュー対象者 1-5, インタビュー対象者 8-4, インタビュー対象者 8-5, インタビュー対象者 8-6
	MLS への信頼(5)	インタビュー対象者 2-11, インタビュー対象者 8-7, インタビュー対象者 8-8, インタビュー対象者 8-9, インタビュー対象者 15-1
自律	ユーザーの感覚に合わせる(2)	インタビュー対象者 9-4, インタビュー対象者 9-5
	MLS 出力の人間による翻訳(2)	インタビュー対象者 11-4, インタビュー対象者 11-5
	MLS への信頼(3)	インタビュー対象者 9-6, インタビュー対象者 9-7, インタビュー対象者 11-6
	MLS への不信(3)	インタビュー対象者 9-8, インタビュー対象者 9-9, インタビュー対象者 11-7

表 5-8 人間・機械協働の特徴の出現数

	可視化	人間中心 ML 補助	ML 中心人間補助	自律	小計
ユーザーの感覚に合わせる	1	4	2	2	9
ユーザー参画への努力	1	9	3	0	13
MLS 出力の人間による翻訳	0	3	4	2	9
MLS への信頼	0	3	0	3	6
MLS への不信	0	3	5	3	11
小計	2	22	14	10	48

人間・機械協働の特性を理解し、機械学習応用システムの深化を進めていくことが不可欠である。初期フェーズではユーザーの参加意識を高め、ユーザーの感覚に応じながら機械学習応用システムを調整する必要がある。段階的なリリース時は、人間による機械学習応用システムの解釈・翻訳が必要となる。

ユーザーの機械学習応用システムへの信頼は、システムが効果的な意思決定を行っており、出力値の正確性にも問題がなく運用されていることが前提となる。言い換えれば、信頼とは、ユーザーが機械学習応用システムによって提供される情報の信頼性と信憑性を認識できる状態を指す。機械学習応用システムに対する信頼は、ユーザーにとって有用であり、効果的な意思決定プロセスを可能にするだけの信頼できる情報を提供できるかどうかに関連している。逆に、システムへの信頼が低い状態とは、ユーザーがシステムの出力を信頼できないと感じる状態を指す。例えば、システムが誤った情報を出力しているとユーザーに認識される場合、ユーザーはシステムの出力を疑う傾向にある。機械学習応用システムが意図的に操作されている可能性がある場合や、データの品質が低い場合、ユーザーはシステムの出力に対する信頼が低くなり、これは人間系を含んだ機械学習応用システム全体の有用性とパフォーマンスの評価に影響を与える。

1. 機械学習応用システムへの信頼

人間中心 ML 補助の際、機械学習応用システムは運用されている。機械学習応用システムへのユーザーの信頼は、主に 2 点から論ずることができる。1 点目は、人間は多少の誤差が生じる可能性があることを理解したうえで、システムの出力値を解釈していることである。これは、ユーザーが機械学習応用システムの精度が 100%ではないことを認識しているために行われる。ユーザーはビジネス実行のために機械学習応用システムの出力を評価する。2 点目は、データに基づいて帰納的に分析されるため、公平性が高いとユーザーが感じられることである。これは、機械学習応用システムが人間が処理できないほどの大容量データを短時間で扱うためである。

- (1) 人間は多少の誤差があることを理解し、機械学習応用システムの出力値を解釈する

「プロジェクト異常の点数を公開すると反発があったりする。公平性も気にする。モデルが 100%正しいわけではない。一中略一不公平な結果は出ることがあるが、その意味合い、結果の解釈が必要となる。」（インタビュー対象者 1-4）

「機械学習応用システムによる回答は 60-70%正確ですが、現場はそれを受け入れます。システムからの情報をどのように絞り込むかは人間の仕事です。つまり、AI と人間は協力して働いています。」（インタビュー対象者 14-4）

- (2) データに基づいて帰納的に分析されるため、公平性が高い

「公平性の面で、機械学習応用システムの出力は人事評価に使用されます。一中略一配送をちゃんとやるのがスタッフの仕事、付加価値となる。巡回タイミングは今回のシステムである程度公平化できた。」（インタビュー対象者 2-11）

「物流（計画を機械学習により最適化すること）に関しては現場が反対することがない。なぜならばデータを基にして物流が動いているためである。計画系で人系オペレーションが存在しない。人ではやりきれないスケールの仕事である。」（インタビュー対象者 9-6）

「最初商品を取り入れるときは感覚で（人間が最初の在庫計画を作成）やっている。データがたまるとデータ駆動にしている。」（インタビュー対象者 9-7）

「AI が出力することによって、公平性が上がる。そのためのトラブルが減る。検査員の習熟度によるデータのばらつきのリスク回避ができる。」（インタビュー対象者 15-1）

2. 機械学習応用システムへの不信

機械学習応用システムが難しいタスクに対して常に効率的または効果的な解決策であるわけではなく、その際にユーザーは機械学習応用システムを信用しなくなる場合がある。不信は、機械学習応用システムの出力を人間が解釈できない場合に発生する。これは、出力がしばしばブラックボックスであるためである。さらに、ユーザーやエンジニアでさえも機械学習応用システムの出力に自信を持ってない場合がある。そのような場合、ユーザーは適切な解釈を行うことができず、これが機械学習応用システムへの不信感につながる場合がある。ユーザーは、機械学習応用システムの出力が直接顧客に関連する場合、社内向けのシステム以上にその品質を気にする。技術的には、機械学習応用システムを使用して顧客と直接コミュニケーションをとることは可能であるが、ユーザーはリスクのある振る

舞いや顧客からのクレームを懸念している。これは合理的な懸念であり、システムの成熟につれてリスクを減らすことが必要である。

(1) MLS の出力が解釈できず、不信感につながる

「(機械学習応用システムは) 出てきた結果がブラックボックスになるので、プロセス議論ができない。結果が悪くないとダメだねとなってしまう。」(インタビュー対象者 9-8)

「AI がどういいか作っている人しかわからないし、作っている人でも 100%理解しているわけではない。」(インタビュー対象者 11-7)

「(機械学習応用システムの) 精度を上げて機械が中心になるかどうかは開発計画にはあるものの、賛同を現在得られるかどうか」(インタビュー対象者 14-6)

(2) 顧客と直接つながる際の MLS の品質についての配慮

「倫理上の問題が出るのは、お客さんにリコmendをする際。気持ち悪さがおきる。」(インタビュー対象者 9-9)

「(リスク対応は) 最後は人。最後 (対象システムの最終目標) のフェーズは AI が自動でメールを出す。お客様の取引サイドに通知を出す。これがあるとリスクがあるが。」(インタビュー対象者 13-8)

5.6. 本章の分析

5.6.1. 機械学習応用システムの深化プロセスの分析

機械学習応用システムの深化プロセスの特徴と困難を 5 章 4 節で明らかにしてきた。特徴と困難は表 5-6 にまとめたソースを基に構成されている。それぞれの機械学習応用システムの深化プロセスの次ステップに至る条件を本項表 5-9 にまとめた。コンディションは論理的に導き出した。

ステップ 1：可視化は、データ結合プロセス、ユーザー要求の具体化、ユーザーへの仮説提示において様々な課題に直面する段階であり、この過程でユーザーは試行錯誤のアプローチによって目標を達成することになる。このプロセスは、機械学習応用システムを開発する初期段階において特に重要である。深化プロセスでは、データソースの特定とデータの統合処理、デジタルプラットフォーム活用がデータ結合プロセスの一環として含まれる。また、ビジネス仮説の設定と可視化は仮説検証アプローチで取り組まれる。問題解

決においてユーザー中心のアプローチを確保するためには、ユーザー部門との共創チームを確立することが求められる。

ステップ 2：人間中心 ML 補助は、機械学習が動き始めるタイミングである。この段階では、ユーザーの期待は一般的に高く、AI の活用に際して遭遇する困難を解決するために、機械学習応用システムの使用に積極的な人間の介入が必要とされる。ユーザーは、システムの出力を解釈し、それを自身の要求に適合させることによって、システムの調整を行う必要がある。人間中心の ML 補助における期待管理では、ユーザーと協力して期待値を明確に定義し、プロトタイプを定期的に共有し、利用上の制約をはっきりさせるプロセスが含まれる。AI を活用する際の困難を克服するためには、効果的なコミュニケーションが欠かせず、ユーザーフレンドリーな UX/UI の設計やユーザートレーニングなどがそのために必要となる。さらに、積極的な人間の介入を通じて、ユーザーが機械学習応用システムの出力を適切に解釈し、より良い学習データの収集を促すことも重要である。これらの活動は、ユーザーがシステムをより深く理解し、その出力を自身の仕事や要求に適合させることを助ける。

ステップ 3 では、機械学習応用システムが一定の信頼を獲得し、利用率が高い状態になり、ML 中心人間補助が実現している状態である。この段階では、パイプラインジャングルやデータエンジニアリングの難しさに直面することがあり、エラーが生じることもある。そのため、人間は機械学習応用システムの修正に介入し、システムの成熟を促す必要がある。目標は、システムの精度と信頼性を高め、意思決定プロセスにおける人間の介入を減らすことである。ユーザーとの信頼は、システムがビジネス環境で正確に機能し、その出力が妥当であることをユーザーに理解してもらうことを意味する。ML 中心人間補助の実践においては、パイプラインの簡素化、明確なドキュメント提供、そしてユーザートレーニングがパイプラインジャングルを解消するために不可欠である。システムの成熟には、ユーザーのシステム開発プロセスへの積極的な参加、モデル品質向上のためのトレーニングデータの継続的な収集、そしてシステムの適切なモニタリングが必要とされる。ユーザーとの信頼関係を築くためには、継続的な教育が重要であり、ユーザーがトレーニングデータの収集に積極的に関与し、システムが予期しない振る舞いをした際に迅速に対応できるようにすることが求められる。このようにして、ML 中心人間補助の段階では、技術的な課題の解決だけでなく、ユーザー教育と積極的な参加がシステムの成功において重要な役割を果たす。ユーザーがシステムの動作原理を理解し、その出力を適切に利用することが、人間系および機械系双方を含めたシステムの成熟とビジネス環境での有効活用へとつながる。

ステップ 4 である自律の段階では、機械学習応用システムはエラーが少なく耐障害性に優れており、内部の異常反応に効果的に対処するためのシステム状態の可視化、自己診断、および自己修復機能を備えている必要がある。これらの機能によって、ダウンタイムを最小限に抑え、ビジネスプロセス内でのシステムの信頼性と効率性を保証することが可

能となり、結果としてビジネスの連続性を維持することができる。この自律性の実現において、データ駆動型オペレーションが重要な役割を担う。具体的には、データに基づいた意思決定の実行、データ品質管理を通じた正確性の確保、およびデータ分析に基づく予測値の妥当性の定期的な検証が含まれる。これらの取り組みは、機械学習応用システムが現実世界の環境を理解、適応しながら持続的に高い性能を発揮するために不可欠である。自律性の段階では、機械学習応用システムが自らの状態を監視し、必要に応じて適切な対処を行う能力に加えて、データの品質と分析の正確性に焦点を当てることが、システムの長期的な成功に対する鍵となる。

機械学習応用システムにおける自律は、全知全能型 AI とは異なるものである。ある一定のジョブを定義し、その中で自己診断・自己修復による耐障害性の向上や、ターゲットが変わるコンセプトドリフトや入力データが変わるデータドリフトの認識とモデル再作成の自動化などが、機械学習応用システムの自律の定義である。5 章 6 節 2 項で論じた人間とのコミュニケーションや絆もユーザーからは求められており、人間・機械チームングの概念では個性を主張することも一つの解決策になると考えられる。例えば、信頼度を重視するジョブでは信頼度を高める表現を用いたり、ユーザーを説得するタイプのジョブでは解釈可能性を高めたりといった個性を持たせることが考えられる。

表 5-9 機械学習応用システムの深化ステップの次ステップに至る条件

深化プロセス	特徴と困難	コンディション
可視化	データ結合プロセス	データソースを明確にし、データを組み合わせで可視化する。
	仮説検証プロセス	事業仮説を立て、検証を繰り返す。
	ユーザーとの共創	ユーザー中心の課題解決に向けたユーザーとの共創チームの設立する。
人間中心 ML 補助	過度に高い AI への期待値	ユーザーの期待を共同で定義し、プロトタイプを定期的に共有し、制約を明確にする。
	AI の活用困難性	使いやすい UX/UI の定義やユーザートレーニングなど適切なコミュニケーションをユーザーに対して実施する。
	積極的な人間の介入	使いやすい UX/UI の定義やユーザートレーニングなど適切なコミュニケーションを実施 機械学習応用システム の出力を解釈し、ユーザーに説明を提供する。
ML 中心 人間補助	パイプラインジャングルとデータエンジニアリングの難しさ	パイプラインを簡素化および合理化し、パイプラインをより小さく管理しやすいコンポーネントに分割し、明確なドキュメントとトレーニングをユーザーに提供する。
	システムの成熟化	ユーザーの積極的な参加を促し、システムのリリースサイクルを短縮する。 学習データを継続的に追加してモデルの品質を向上させる。

		モデル監視システムでシステムを監視する。
	ユーザーとの信頼	ユーザーへの教育を継続的に実施する。 データの収集にユーザーを積極的に参加させる。 システムが予期せぬ動作をした場合には、速やかに対応する。
自律	異常系処理の難しさ	異常系処理時の対応決定、システム状態の可視化、自己診断・自己修復機能を提供する。
	データ駆動型 オペレーション	データに基づいた意思決定を行う。 データ品質管理を実行して正確性を確保する。 データ分析に基づいた予測値の妥当性を定期的に検証する。

5.6.2. 人間・機械協働における分析

機械学習応用システムの深化プロセスにおける特徴と困難を5章4節で整理し、機械学習応用システムの深化プロセスにおける困難を解決する方法を5章6節1項で示した。機械学習応用システムの深化プロセスで人間・機械協働が確認できたがうまくいくケースといかないケースで信頼がキーワードになることを5章5節で発見した。本項では人間が機械を信頼するためにはどのような要素が必要かを4章で収集したデータから考察したい。Siau and Wang(2018)は機械学習における信頼を確立する要素を示している(表 5-10)。機械学習応用システムの深化プロセスに則り人が信頼を構築するのは継続的な信頼発展にあると考え、パフォーマンスにある5つの特徴(※印)を設問として採用し、4章3節の二次分析にてデータを収集した。T検定はSmartPLS Ver4.1.0.2、主成分分析はSPSS Ver29.0.2.0(20)、多変量解析はMS Excel Ver2403を用いた。

表 5-10 AI との信頼構築に影響を与える要素

ステージ	カテゴリ	特徴
初期の信頼形成	パフォーマンス	表現
		イメージ/認識
		他のユーザーからのレビュー
	プロセス	透明性と説明能力
		試用可能性
継続的な信頼発展	パフォーマンス	利便性と信頼性※
		協力とコミュニケーション※
		社交性と絆※
		セキュリティとプライバシーの保護※
		解釈可能性※
	目的	職務の代替
		目標の一致

(Siau and Wang (2018) から筆者作成)

各因子間で t 検定を行い、p 値の確認を行い統計上有意かを確認した。t 検定の結果を表 5-11 に記す。赤字で示した箇所が p 値が有意水準目標の 5%を超えている。MLS exploitation と HMC factor の分析は p 値が高く統計上有意ではない。本考察では MLS exploitation と HMC factor の関係性を分析するが、統計上の有意性について割り引いて考える必要がある。

表 5-11 HMC factor の T 検定

	Standard deviation	T statistics	P values
MLS exploitation -> HMC factor	0.076	0.620	0.535

分析は2段階で行った。1段階目は機械学習応用システムの深化プロセス（MLS exploitation）のステージ別に人間機械協働因子（HMC factor）がどのように変化するかどうかである。2段階目は人間機械協働因子（HMC factor）を主成分分析にかけてユーザーにどのような特徴が考えられるかを考察した。

1 段階目の機械学習応用システムの深化プロセスのステージ別人間機械協働因子の変化について記述する。図 5-8 は機械学習応用システムの深化プロセスのステージ別に人間機械協働因子（HMC factor）を整理した 100%積み上げ棒グラフである。それぞれの深化プロセスのステージごとに人間機械協働因子（HMC factor）の 5 段階設問で 4 または 5 を選んだ被験者の数を合計している。人間機械協働因子（HMC factor）は以下の 5 つの要素となっている。

- ・利便性と信頼性：AI 技術が便利で信頼できるものであること
- ・協力とコミュニケーション：人と協力してコミュニケーションが取れること
- ・社会性と絆：社交性があり絆を形成できること
- ・セキュリティとプライバシー保護：セキュリティとプライバシーが守られること
- ・解釈可能性：AI の結果がどう導かれたのかを説明できること

可視化では機械学習は使われていないため被験者の想像での回答となる。機械学習を使っていないユーザーからセキュリティとプライバシー保護や解釈可能性について高い数値を示している。人間中心 ML 補助のユーザーでは協力とコミュニケーションの値が高く、次いで解釈可能性が高い。ML 中心人間補助では、解釈可能性とセキュリティとプライバシー保護が同数で高い数字を示している。自律ではセキュリティとプライバシー保護の値が高い。

解釈可能性は運用のステージが上がると総じて下がる傾向にある。これは機械学習応用システムの挙動を人間が理解しているためと推察できる。また、人間または ML が補助している際はセキュリティとプライバシー保護は低い値を示し、利便性と信頼性は高い値を示す。これは機械学習応用システムの深化プロセスにおける人間・機械協働では利便性と信頼性が重きを置かれる。これは、機械学習応用システムが活用できるということを関係者が理解することが重要であるためと推論できる。また同期間におけるセキュリティとプライバシー保護は補助期間中は一定の制御が人間により入るためか低い値を示した。人間中心 ML 補助で最初に ML が入る際は協力とコミュニケーションに重きが置かれた。これは機械と人間の協力関係を築く最初のステップであり、ユーザーを巻き込みながら信頼を助成していくステップでもあり妥当な結果と言える。最後の自律のステージでは人間の手を離れて機械学習応用システムが自律的に稼働するために高いセキュリティとプライバシー保護が求められる事がわかる。




図 5-8 機械学習応用システムの深化プロセスのステージ別の人間機械協働因子

2 段階目の人間機械協働におけるユーザーの特徴を述べる。4 章で収集した人間機械協働因子（HMC factor）を主成分分析にかけた。結果を表 5-12 に示す。主成分分析から累積寄与率 84.4%の成分 3 までを対象とした。成分に含まれる上位 2 つの変数を元に、成分 1 から成分 3 までの解釈を行った。

表 5-12 HMC factor の成分行列

	成分		
	1	2	3
利便性と信頼性：AI 技術が便利で信頼できるものであること	0.786	-0.093	-0.518 ※3
協力とコミュニケーション：人と協力してコミュニケーションが取れること	0.829 ※1	-0.041	-0.179
社会性と絆：社交性があり絆を形成できること	0.723	0.658 ※2	0.092
セキュリティとプライバシー保護：セキュリティとプライバシーが守られること	0.795	-0.393 ※2	0.228
解釈可能性：AI の結果がどう導かれたのかを説明できること	0.810 ※1	-0.070	0.380 ※3

成分 1 の名称：一般的なユーザー

特徴：全般的に高い期待値

主な因子：協力とコミュニケーション (0.829)、及び解釈可能性 (0.810)

第一の成分は、AI との効果的なコミュニケーションを望みつつも、その過程で解釈可能性が重要であることを示している。ユーザーは機械学習による協力を重視する一方で、その出力値を解釈を求めている。セキュリティとプライバシー保護や利便性と信頼性の値も高く出ており多くの要素で期待値が高い状態である。

成分 2 の名称：AI 活用者

特徴：AI は仕事のパートナー

主な因子：社会性と絆 (0.658)、セキュリティとプライバシー保護 (-0.393) ※2

第二の成分は、機械学習に人間と同様の社会的行動や絆を形成する能力を求める傾向を表している。この要素は、AI が単なる道具ではなく、チームとして相互にコミュニケーションが可能であることの重要性を強調しており、人間・機械チームング (Human machine teaming) の概念を体現しているといえる。半面セキュリティやプライバシー保護への関心は低い。

成分 3 の名称：AI 翻訳者

特徴：ロジックの深堀に興味

主な因子：利便性と信頼性 (-0.518) , 解釈可能性 (0.380) ※3

第三の成分は、利便性と信頼性を犠牲にしても解釈可能性が重要であるという傾向を示

している。この成分3ではAI ロジックの深堀をする翻訳者の気持ちが現れているといえよう。機械学習出力を解釈することに重きを置いており、そのためには利便性と信頼性が下がっても問題ないと考えている。

これらの分析結果は、機械学習へのユーザーの期待を理解し信頼を獲得することための要素を示しており、ステージ別の人間機械協働因子と組み合わせて考察することで人間・機械協働をスムーズに形にするための要素と洞察を提供している。主成分分析のまとめを表 5-13 に示す。

表 5-13 人間・機械協働のユーザー像

成分	名称	主な因子	説明
1	一般的なユーザー	協力とコミュニケーション (0.829)、解釈可能性 (0.810)	AI との効果的なコミュニケーションとその出力の解釈が重要。セキュリティ、プライバシー保護、利便性、信頼性への期待も全般的に高い。
2	AI 活用者	社会性と絆 (0.658)、セキュリティとプライバシー保護 (-0.393)	AI がチームの一員として機能し、相互コミュニケーションを行うことの重要性を意識。セキュリティとプライバシーの保護への関心は相対的に低い。
3	AI 翻訳者	利便性と信頼性 (-0.518)、解釈可能性 (0.318)	解釈可能性を重視し、AI ロジックの深堀に興味がある。利便性と信頼性を犠牲にしても問題ないと考えている。

5.7. 小括

機械学習応用システムの深化プロセスはデータの可視化、人間中心 ML 補助、ML 中心人間補助、自律と 4 つのステップで進化していく一連のプロセスである。可視化ではデータ結合プロセス、仮説検証、ユーザーとの共創といった特徴がみられ、機械学習を導入する前のユーザーとのすり合わせを行うステップでもある。人間中心 ML 補助では、過度に高い AI への期待値、AI の活用困難性、積極的な人間の介入といった特徴がみられ、機械学習が導入するタイミングでの様々な困難が表面化しそれを積極的に人間が介入し理解を深めていくステップである。ML 中心人間補助はパイプラインジャングルとデータエンジニアリングの難しさ、システムの成熟、ユーザーとの信頼といった特徴が見られ複雑化する技術的な課題が表面化すると同時にユーザーからの信頼を獲得するステップでもある。自

律は異常系処理の難しさ、データ駆動型オペレーションといった特徴がみられ、システムとしての自律性を実現するためにエラーの最小化と耐障害性の向上を行い、データ駆動オペレーションが実現している状態である。

これらの困難を人間・機械協働により解消している。ここでは人間系と機械系が連動して完全なシステムとして機能しており、相互に適応する双方向のプロセスを有する。機械による予測や分析結果を人間が解釈しユーザーに伝える翻訳者としての動きが期待され、これによりユーザーが機械を信頼するに至る。人間・機械協働ではユーザーの種類を一般的なユーザー、AI 活用者、AI 翻訳者と3つの成分で説明できる。一般的なユーザーは一般的に高い期待値があり、AI との効果的なコミュニケーションを望みつつも、その過程で解釈可能性が重要であることを示している。AI 活用者は機械学習に人間と同様の社会的行動や絆を形成する能力を求める傾向を表しており、セキュリティやプライバシー保護への関心は低い。AI 翻訳者は利便性と信頼性を犠牲にしても解釈可能性が重要であるという傾向を示している。AI ロジックの深堀をする翻訳者の気持ちが現れている

6. 考察

6.1. 統合的考察

DX の進化は、企業が直面する競争環境に適応し、新たな価値を創造するための重要な戦略である。この文脈において、機械学習応用システムは、中心的な役割を果たしている。DX 進化概念は3章、DX 実行意思及び周辺情報の分析を4章、機械学習応用システムの進化概念及び人間・機械協働概念は5章で詳しく考察した。ここでは各章の統合的な考察と発見事項を3点論じたい。それぞれの対応関係を図 6-1 に示す。1 点目は DX の進化過程における必要な要素の特定である。2 点目は DX 分類と機械学習応用システムの深化の対応関係である。3 点目は人間・機械協働因子である。以下 3 点の発見について考察を展開する。




図 6-1 各章における研究方法と考察の対応

1 点目は DX 3 分類である。3 章 4 節図 3-2 で明らかにしたように 3 つの特徴に分けら

れる。この DX3 分類は DX 実行意思 (DX intention) と相関関係があることが示された。つまり、DX 3 分類を推進するためには DX 実行意思を上げることが効果があるということである。また DX 実行意思を上げるには、DX への態度 (Attitude toward DX)、スキルや能力に関する自信 (Perceived competence) との相関関係が強く、因果関係は定かではないがこの 2 点を向上させることが DX 3 分類の推進に関係性があることが示された。本発見事項を示すモデル図を図 6-2 に示す。




図 6-2 DX 進化過程における必要要素

2 点目は DX 分類と機械学習応用システムの深化の対応関係である。DX 分類の 2 型、3 型にある企業は、機械学習応用システムを通じて、外部アクターに対して積極的な働きかけを行っている。3 章 3 節で取り上げた事例の機械学習応用システムの導入状況を表 6-1 で示す。DX を推進するうえで人間系を含む機械学習応用システムは重要であることがわかる。講演者 1 の在庫配分最適化システムは在庫の置き場と数量を決めるうえで人間系による予測を最初に行うが、ある程度データがたまった段階で機械学習による予測に切り替えている。そのため、ML 中心人間補助とした。講演者 4 のウェブアプリケーションファイアウォールシステムは、不正なアクセスの検知に当初は人間の判断を用いるが、人間の判断したデータを基に学習し自動的に不正アクセスの検知をリアルタイムに行うようになる。この判断は ML 中心ではあるものの、人間に最終的な判断は任されているため ML 中心人間補助とした。講演者 6 はタクシー運転手の売上を最大化するうえで、ベテランドライバーの走行履歴分析や需要分析を基にしたデータセントリックなアプローチを採用している。過去データや需要からドライバーへレコメンドを出すことは人間の手では不可能であり、自律が実現している。

1 型:内部チェーン最適化型 DX で機械学習応用システムを深化させることにより、2 型:バリューチェーン最適化型 DX で他のアクターを呼ぶことが可能である。特に 2 型でコンシューマーを巻き込む場合は機械学習応用システムは ML 中心または自律以上であるべ

きである。これはコンシューマーに対して予測をすることは人間中心のオペレーションでやることは非現実的であるためである。例えば講演者 1 の EC における商品レコメンドや講演者 4 の運用監視、講演者 6 のタクシーにおける高需要予測などがあたる。なお、講演者 2 のように顧客を巻き込んでいる場 B2B の場合は営業マンがたつために ML 中心人間補助でも機能する。

なお、DX 分類と機械学習応用システムの深化の共進化についても考察を行いたい。DX が進化することで機械学習応用システムの深化が相互に進むことを指すが、従来型の共進化は DX 分類といった経営的な意思をもとに技術を適用することが多い。ただし、今後は LLM（大規模言語モデル）の出現といった極めて革新的な技術により経営面に影響を与えることもあり得る。このような新たな動向は、技術から経営へのフィードバックを強め、共進化のダイナミクスに変化をもたらすと考えられる。

表 6-1 事例研究対象プロジェクトの機械学習応用システムの深化プロセス

講演者 No.	プロジェクト	業界	DX 分類	機械学習応用システム	人間系
講演者 1	在庫配分最適化システム	小売業	2 型	ML 中心人間補助	○
講演者 2	販売計画システム	広告業	3 型	人間中心 ML 補助	○
講演者 3	防災システム	ソフトウェア業	3 型	ML 中心人間補助	○
講演者 4	ウェブアプリケーションファイアウォールシステム	情報通信業	3 型	ML 中心人間補助	○
講演者 5	賃貸収益計算システム	不動産業	3 型	ML 中心人間補助	○
講演者 6	運転支援システム	運輸業	3 型	自律	○
講演者 7	駐車場在庫管理システム	不動産業	3 型	人間中心 ML 補助	○
講演者 8	ヘルスケアサービス	製造業	2 型	人間中心 ML 補助	○

3 点目は人間・機械協働因子である。機械学習応用システムの深化プロセスにおける初期段階と後半段階で人間の役割が異なることが観察された。初期段階では、ユーザーの感覚に合わせ、ユーザーが参画する努力をする。これには 2 つの目的がある。1 点目はユーザーの要求と機械学習ができることをすり合わせし、期待値調整をすることである。2 点目はユーザーの支援により機械に学習させるデータを増やし、機械学習応用システムの精度を向上させるためである。一方、プロジェクトの後半段階では、機械による予測や分析結果を人間が解釈しユーザーに伝える翻訳者としての動きが期待される。この相互作用は、機械学習応用システムを成熟させるうえで不可欠なものであり、これにより人間による機械学習応用システムへの信頼が醸成される。信頼を獲得していくプロセスは、機械学習応用システムが単なるツールではなく、業務における参加者へと変化していく過程を示している。DeStefano（2023）は機械学習応用システムへの信頼の構築は開発段階でユーザーが参画することで深まることを示しており、開発中のプロセスにおける信頼関係の構

築方法を本論文では示したといえる。

信頼を獲得するうえで、必要な要素を 5 章 6 節 2 項の図 5-8 で示した。当初は協力とコミュニケーションや解釈可能性が重要であるが、機械学習応用システムの深化プロセスが進み人間・機械の信頼関係が醸成されるにつれてセキュリティとプライバシーなど機械学習応用システムが独り立ちするにあたっての要件が増えてくることがわかる。これは、人間・機械チームング (Human machine teaming) で言われる、AI を一人の新入社員として遇してトレーニングをしながらチームメイト (Babic et al. 2021) として関係性を醸成していく様に当てはまる。

人間・機械協働を深めることで、機械学習応用システムのポテンシャルを最大限に引き出し、DX を加速させることが可能となる。この複合的なアプローチにより、企業は DX を推進しながら持続可能な成長を実現し競争優位を確立することができる。

4 章 3 節で分析した通り、人間機械協働因子は機械学習応用システムの深化プロセスにおけるステージとの相関関係は出なかったが DX3 分類とは強い相関関係が認められた。ここでのモデル図を改めて図 6-3 に示す。




図 6-3 人間機械協働因子と DX 分類の関係性

6.2. 先行研究との関係性

本節では、本論文の主となる概念である、人間・機械協働をいくつかのディシプリンを元に考察をする。また、知識科学の視点で人間・機械協働がどのように位置づけられるかを考察する。2 章 6 節に人間・コンピューターインタラクション (Human computer interaction)、人間・機械インタラクション (Human machine interaction)、人間・機械

協働(Human machine collaboration)、人間・機械チームング(Human machine teaming)の関係整理を整理した。その中で人間・機械協働は「人間と機械が協力して作業を行うプロセス。機械は単なるツールではなく、人間のパートナーとして位置づけられる。機械は独自の「知能」や意思決定能力を持ち、人間の作業を支援し、拡張する。共有作業スペースで人間とロボットが共同で作業を行う工場などが該当する。」と記述した。機械学習応用システムにおける人間・機械協働は協力して作業をし、人間が機械を信用することで関係性が強化され結果的に人間中心の業務から機械中心の業務に徐々に移行していくことが5章4節で確認できた。また、機械独自の「知能」や意志決定は帰納的ソフトウェア開発によりデータセントリックに行われるため、人間のジャッジも含め機械は学習している。人間の作業の支援や拡張においては、人間では処理しきれない大量の情報や即時に処理されるスピードが機械学習応用システムにより実行されることも確認できた。

人間拡張の視点では、コンピュータがビッグデータを活用し機械学習を活用し計算処理を行うことで人間の能力を拡張することができる。Daugherty and Wilson(2018)はミッシングミドルで、AI による人の能力の拡張は、増幅、相互作用、具現化にあるとした。ただし、機械をうまく人間が使いこなせることが重要であり、機械の出力が安定していないと人間はうまく活用ができない。機械からの出力を安定化させ、機械を人間が信頼することで活用に繋がり人間拡張は実現する。人間が機械を信頼するためには5章6節2項で論じた通り、機械を信頼するための要素が必要である。

Gefen et al. (2003)は信頼を組織内での対人関係間での信頼形成やインターネット上での信頼関係、取引関係にある企業間の信頼をレビュー論文としてまとめた。組織内での対人関係は他者の行動によるリスクを負うことを意味しており、その脆弱性をいとわない状態を指す。その他の観点では、信頼される側に能力、正直さ、慈悲、誠意があることや他者へ頼る意思を持つことなどが並ぶ。

人間・機械の信頼 (Human machine trust)の視点では、Lin et al. (2024)は Human machine interaction 観点では対人関係の信頼から人間と機械の間の信頼に変化している点を示した。ここでは人間と機械は相互に信頼しあうわけではなく、信頼者は人間であり、信頼される側は機械である。Lee and See (2004)はオートメーションにおける信頼とその影響を動態モデルとしてコンセプトモデルを示した。ここでは信頼は評判や噂から利用者が信念を形成し、信頼進化に向けて組織構造や文化などの環境要因やリスク自体の認識や依頼者の自信による意図形成がオートメーション化への意思につながる。機械との信頼のためには調整 (Calibration)、解決能力、時間と機能的な特性により信頼が出来上がるとした。このモデルは人間・機械の信頼モデルの基礎となっているがオートメーションを対象としており、本論文のテーマである機械学習応用システムとは異なる対象である。Siau and Wang (2018)は AI における信頼の要素を示した。信頼は初期的なものと継続的なものに分けられるとした。初期的なものは、表現、認識、他のユーザーからのレビューなどを挙げている。継続的な信頼要素は、利便性と信頼性、協力とコミュニケーション、社交性

と絆、セキュリティとプライバシーの保護、解釈可能性を挙げた。

機械学習応用システムの開発における継続的な信頼の変化を分析対象とした点が本研究の新しい点であり、具体的には機械学習応用システムの深化プロセスのステージごとに、人間が機械を信頼するうえでどのように要素が変わるかを示した点が本研究の新規性である。

Ergonomics と Applied human factors にも触れておきたい（表 6-2）。日本語では両者ともに人間工学と訳される。Ergonomics は、人間を工学的分析することにより人にとって使いよいデバイスの在り方（作業や機械）を対象とした学問分野である。人間の四肢や身体の動きを工学し、操作しやすい車のコクピットを作るなどが Ergonomics にあたる。また Applied human factors は対象が人間の認知的側面に焦点をおき、情報処理や意思決定、認知心理、人間と機械の相互作用を研究の対象とする。人間とシステム間の相互作用を最適化するといった点で、本研究の人間・機械協働は Applied human factors に属する。次に説明する知識科学観点での人間・機械協働プロセスも Applied human factors に含まれる。

表 6-2 Ergonomics と Applied human factors

項目	Ergonomics	Applied human factors
定義	人間の能力と制約を考慮して、作業、機器、環境を最適化する学問分野。	人間の能力、制約、特性を考慮して、製品、システム、環境を設計および評価する学問分野。
重視する点	物理的側面、例えば筋骨格のストレス、作業ステーションのデザイン、物理的作業の効率化など	認知的側面に特に焦点を当てており、情報処理、意思決定、認知心理学、人間と機械の相互作用など
目的	人間の物理的快適性と効率を最大化し、関連する健康問題や傷害を最小化する	人間とシステム間の相互作用を最適化し、効率、安全性、快適性を向上する

知識科学の視点でも議論を行いたい。知識創造プロセスで人、組織、環境の 3 つの概念が定義されている（野中・竹内 2020）。人は知識の生成、保存、共有、応用といった知識活用を行う主体である。組織は個人が集まり、共同で目標を達成するための構造体であり、知識の活用を行う場でもある。環境は個人や組織が存在し、知識活用が行われる状況を指す。AI は、その構成要素であるデータやインフラ、計算機などは環境として整理できるが、知識生成や意思決定支援といった観点では人に近い概念として位置づけられる。本論文では、AI を人の概念として取り扱う。これは、AI の出力を人がどのように捉えるかにより人間・機械協働が完成するという観点であり、人は AI を擬人化して考え、信頼を基に AI の出力を解釈するためである。

知識のライフサイクル観点で人間・機械協働は知識の生成、共有、応用に寄与する。具体的には、機械の出力を人間が翻訳することで新たな解釈が生まれ、新たな知識が生成される。知識生成のノウハウは翻訳者から現場のユーザーへと伝えられ、人間・機械協働による知識の生成方法および知識そのものが共有される。翻訳者を通じて機械の出力がユーザー全体に広まることで、知識が実際の問題解決に応用され、人間・機械協働の知識ライフサイクルは一巡することになる。

知識創造プロセスの観点では、知識の活用方法は翻訳者が最初にその役割を果たすが、これは機械への興味や組織内の役割からくるものであり、暗黙的に機械学習応用システムを用いながら習得する。この段階は SECI プロセス (Nonaka and Takeuchi 1995) では共同化 (Socialization) と定義できる。翻訳者として当初暗黙知である人間・機械協働を徐々に形式知にしていくことで表出化 (Externalization) の段階となる。表出化された形式知を機械学習応用システムを用いるユーザーが理解することにより、自身の業務に適した形で機械学習応用システムの出力と翻訳者の理解を再構成する。これが統合化 (Combination) である。最終的に実際の業務に適用することで内面化 (Internalization) を行い、人間・機械協働が組織内に取り込まれる。

人間・機械協働を含んだ知識科学では人間と機械が協働しながら知識創造するプロセスが研究対象に含まれる (図 6-4)。人間・機械協働では機械に対する信頼が重要であり、この信頼構築は機械学習応用システムの深化プロセスのステージごとに必要となる要素が変化する。本研究では、機械学習応用システムの開発を含んだプロセスの特徴と課題をまとめ、そこで人間と機械の協働に必要な要素を特定したことが新しい。この研究は知識科学として、「人間系を含んだ機械学習応用システムにおける知の創造の要素」を示すものとなる。




図 6-4 人間・機械協働を含んだ知識科学の対象

北陸先端科学技術大学院大学では3点の論文が人間・機械協働プロセスについて言及をしている。1点目はリスクマネジメントにおける機械参加型（machine in-the-loop）プロセス（森 2020）では、意思決定における人間と機械の関係性をモデル化した。これは二重過程理論やプロスペクト理論に基づいており、リスクマネジメントにおける理想的な人間・機械協働のプロセスを提示した。2点目は、多段階在庫配置問題に人と機械の協働プロセス（小倉 2023）を提言した。先行研究から、意思決定を情報活動、設計活動、選択活動の3プロセスに分類し、人が得意な業務と機械が得意な業務を示した。また複数主体の意思決定プロセスをモデル化し、プロセスを提示した。3点目は弁理士業務におけるAIの活用（白坂 2021）である。弁理士の「特許性の直観的把握力」に着目し、発明者と弁理士が行う発明会議にAIが持ち込まれた際に、発明者と弁理士にどのような影響があるかを考察した。表 6-3 に知識科学の観点での人間・機械協働プロセスを整理した。

表 6-3 知識科学観点における人間・機械協働プロセスの研究

著者	年度	論文名	概要
森 俊樹	2020	リスクマネジメントにおける機械学習と知識創造の統合アプローチ—機械参加型（machine-in-the-loop）プロセスの提案—	プロジェクト・リスクマネジメントを取引コスト理論およびプロスペクト理論の観点から考察を行い、その解決アプローチとして人間の気づきと機械学習の相補性に着目した機械参加型（machine in-the-loop）リスクマネジメントを提案した。機械学習モデルの予測・推定結果を人間が解釈して意思決定に反映させるためにモデルの解釈可能性が重要である点を示した。またモデルの解釈可能性を上げるために、新しい機械学習モデル SNB（superposed naive Bayes）を提案した。
小倉 孝裕	2023	複数目的・複数主体からなる多段階在庫配置問題の意思決定における人と機械の協働プロセス	多段階在庫配置問題において、人と機械の協働プロセスを提言し、人の意思決定にどのような影響があるかを明らかにした。機械が得意な作業として、情報活動と設計活動をあげ、選択活動を複数主体と機械が対話型で意思決定を行う協働プロセスを提案した。
白坂 一	2021	AI と弁理士の協働による進歩性判断—先行特許文献調査システムの発明現場への導入—	特許実務の専門家が進歩性判断の際に用いるクレームチャートを出力できる先行特許文献調査システムを開発した。本システムの活用において、弁理士の「特許性の直観的把握力」に着目し、知識と経験以外にどのような要因を有するかを追及するとともに、AI を用いることで、この力がより熟達し、AI と弁理士の協働を可能とすることを示唆した。発明者と弁理士が行う発明会議に AI が持ち込まれた際に、発明者と弁理士にどのような影響があるかを考察した。

7. 結論

本研究では、技術的不確実性のある機械学習応用システムの漸進的な開発手法を明らかにした。本章では、1 節で本件のまとめを行い、2 節でリサーチ・クエスチョンへの回答を述べる。3 節・4 節で理論的貢献と実務的貢献を述べ、最後に 5 節で本研究の限界と将来研究への示唆を示す。

7.1. 本研究のまとめ

デジタルトランスフォーメーション 3 分類と進化過程 (3 章)

DX は 3 つに分類できることが帰納的テーマティック・アナリシス法による質的分析で明らかになった。本分類は、DX3 分類と名付け、それぞれ 1 型 内部チェーン最適化型 DX、2 型 バリューチェーン最適化型 DX、3 型 新事業価値創造型 DX である。1 型 内部チェーン最適化型 DX は、企業内のデータを最適化することから成る。2 型バリューチェーン最適化型 DX は、協力会社や顧客といった外部のアクターを巻き込むことで DX のモデルを強化することである。3 型 新事業価値創造型 DX は、1 型、2 型のデータを基に新しいビジネスモデルを構築することを指す。DX3 分類のそれぞれの特徴は、表 3-5 にテーマ、コード、サブコードをまとめてある。3 分類を企業がどのように進化したかを表 3-9 にまとめた。これは、DX の進化は、1 型から始まり、徐々に 2 型を経て 3 型に至るという一連の進化過程を辿る。このプロセスは、内部データの蓄積、バリューチェーンの最適化、そして新たなビジネス価値の創造に至るまで、段階的に進行する。

また、1 型から 3 型にいたるプロセスには 3 つのパターンが存在する。1 点目はオペレーションエクセレンス型、2 点目は自己充足型、3 点目は共創型である (表 3-10)。これを DX の進化パターンとした。1 点目のオペレーションエクセレンス型は、1 型から始まり、2 型を経て 3 型に至るまでのプロセスが非常にスムーズであることが特徴である。本アプローチは、外部パートナーとの多数の協力関係に基づく成熟したビジネスモデルであり、オペレーションエクセレンスが実現されている。この種のビジネスでは、業界のペースに合わせる必要があり、外部パートナーとの密な連携と時間を要する調整が不可欠である。この手法を採用するビジネスは、サプライチェーン構造に与える影響を最小化すべく時間をかけて調整を行うことに大きな特徴がある。2 点目の自己充足型は、2 型のステップを飛ばし、直接 3 型へと移行しているケースである。バリューチェーン全体にわたるサプライヤーとの連携を待つことなく、独自のデータリソースを活用し、新しいビジネスモデルへのシフトを試みている。これは、企業が独自のデータを準備し、それを基にビジネス変革を遂行する能力により 3 型が推進できることを示している。バリューチェーンの観

点から、データを得るためにサプライヤーや顧客と協力する必要性がなく、すべてを内製化していることが大きな特徴である。これにより、外部依存を最小限に抑え、迅速かつ柔軟に市場の変化に対応している。3 点目の共創型は 3 型と 2 型を同時に進行させている。この特性は業界の結びつきが少ない新しい業界や SaaS モデルにみられる。SaaS モデルによるビジネスは、顧客のデータを収集し、そのデータを活用してサービスを進化させることが多い。顧客との共創を通じてデータを収集し、サービスレベルを向上させ、バリューチェーンの最適化を行っている。

DX 実行意思 (4 章)

DX 分類 (DX evolution type) と DX 実行意思 (DX intention) との関係性を調べることに主眼を置いた。二次分析の結果 DX 分類 (DX evolution type) と DX 実行意思 (DX intention) には強い相関関係が確認できた。また、DX 実行意思と相関関係の高い因子を検討した。これにより、起業意識と企業内での DX 実行意思は類似した特性を持ち、理論の援用が可能であることが立証された。具体的には、DX 実行意思 (DX Intention) とスキルや能力に関する自信 (Perceived Competence) 及び DX に対する態度 (Attitude toward DX) との間には、相関関係が見られた。以上の結果は、企業が DX を推進する上で重要な因子と実務的な示唆を示しており、DX 実行意思の育成が DX 成功の鍵であると結論付けられる。

機械学習応用システムの深化プロセス (5 章)

機械学習応用システムの深化プロセスはデータの可視化から始まり、最終的にはシステムの自律へと深化していく一連のプロセスである。ステップ 1: 可視化 Visualization では、データ結合プロセス、仮説検証、ユーザーとの共創が重要である。ステップ 2: 人間中心 ML 補助 Human-centered ML assistance では、過度に高い AI への期待値、AI の活用困難性、積極的な人間の介入といった特徴がみられる。ユーザーの理解と活用促進するために機械学習応用システムをユーザー中心で試行錯誤を繰り返す時期であり人間系・機械系の双方の成熟途上の段階である。ステップ 3: ML-centered Human assistance では、機械学習が中心となり判断を実施する。ただし、エラー時など不測な事態の際は人間がサポートする。パイプラインジャングルとデータエンジニアリングの難しさ、システムの成熟、ユーザーとの信頼といった特徴がみられる。パイプライン最適化、エラー解決範囲の拡大などシステムの継続的な改善が必要であり、同時にユーザーが機械学習応用システムを信頼してもらうためにも十分なコミュニケーションが必要とされる。ステップ 4: 自律 Autonomy では、システムは高い自律性を有しており、エラーを限りなく最小化し、耐障害性が優れている状態である。異常系処理の難しさ、データ駆動型オペレーションと

いった特徴がみられる。自己診断と自己修復機能により、システムのダウンタイムが最小限に抑え、ビジネスの連続性が保たれる。また、データ駆動型のオペレーションが行われ、データ品質の管理、予測値の妥当性の検証が定期的に実施される。

上記に示した困難を解消する際には人間・機械協働により解決が行われている。ここでは、人間系と機械系が連動して完全なシステムとして機能する。相互に適応する双方向のプロセスである。機械学習技術はコンポーネントの集合体であり、機械学習応用システムが運用される際には人間がシステム内に適応する必要がある。人間・機械協働の特性を理解し、機械学習応用システムの深化を進めていくことが不可欠である。初期段階では、ユーザーの感覚に合わせ、ユーザーが参画する努力をする。後半段階では、機械による予測や分析結果を人間が解釈しユーザーに伝える翻訳者としての動きが期待される。この相互作用は、機械学習応用システムを成熟させるうえで不可欠なものであり、これにより人間による機械学習応用システムへの信頼が醸成される。この参加者として変化する過程において機械学習応用システムを信用できるかは重要なポイントとなる。ユーザーの機械学習応用システムを信頼する状況は、システムが効果的な意思決定を行っており、出力値の正確性にも問題がなく運用されている状態である。システムへの信頼が低い状態とは、データの品質が低く、システムが誤った情報を出力している場合や機械学習応用システムが意図的に操作されている可能性がある場合などがある。これは人間系を含んだ機械学習応用システム全体の有用性とパフォーマンスの評価に影響を与える。

7.2. リサーチ・クエスチョンに対する回答

本節では、1章2節で立てたサブシディアリー・リサーチ・クエスチョン(SRQ)について回答し、それらの回答結果を基に、メジャー・リサーチ・クエスチョン(MRQ)について回答する。はじめに、SRQ1の回答は以下のとおりである。

SRQ1：企業におけるDX分類と進化過程は何か？

企業のDXは3つに分類できることが明らかとなった。それぞれ1型 内部チェーン最適化型DX、2型 バリューチェーン最適化型DX、3型 新事業価値創造型DXである。DXの進化過程は、3つのパターンが存在する。1点目はオペレーションエクセレンス型、2点目は自己充足型、3点目は共創型である。

次に、SRQ2の回答は以下のとおりである。

SRQ2：DX実行意思は他要素とどのように関係し、いかにして高めることができるか？

企業担当者の DX に対する態度・興味及びスキルや能力に関する自信が高まると DX 実行意思が高まるという相関関係が認められた。そのため DX に対する態度・興味及びスキルや能力に関する自信を高めることを組織的に行うことで計画的に DX 実行意思に働きかけることができる。また、DX 実行意思が高い被験者は DX3 分類のステージが高い相関関係にあることも分かった。

次に、SRQ3 の回答は以下のとおりである。

SRQ 3：機械学習応用システムの深化プロセスの特徴と困難は何か？困難を解消する際に人間と機械学習応用システムはどのように深化・協働しているのか？

機械学習応用システムの深化プロセスはデータの可視化から始まり、最終的にはシステムの自律へと進化していく一連のプロセスである。ここでの特徴と課題は図 5-6 に詳しい。上記に示した困難を解消する際には人間・機械協働により解決が行われている。人間・機械協働では、人間が機械を信頼できるかどうかが重要である。またこのプロセスに従事する人は様々なタイプが存在し、初期的なユーザーは高い期待値があるが、徐々に機械を信頼することで理想的な役割分担ができることがわかった。人間系を含んだ機械学習応用システムは、ユーザー部門で翻訳者として機能する人がとても重要である。翻訳者とは、機械の出力特性を理解し、その出力値を解釈し人に伝達することである。これは知識科学の観点で、人間と機械が協働しながら知識創造と活用を行っている点が新しい。

最後に、MRQ の回答は、以下のとおりである。

MRQ：企業における DX はいかに進化し、その過程で人間と機械学習応用システムはどのように深化・協働するのか？

DX を推進するうえで人間系を含む機械学習応用システムは重要である。DX 3 分類のステージが切りあがることで関わるアクター数が増加する。機械学習応用システムは帰納的ソフトウェア開発が特徴であり、それに伴う様々な課題も触れてきた。この新しい開発プロセスにユーザーも慣れていない。機械学習を用いる人間中心 ML 補助以降は、テクニカルな課題と機械学習応用システムをユーザーが受容し、変容しながら利活用するといった人的な課題がある。初期段階のユーザーによる直感的フィードバックは、機械学習応用システムのパフォーマンスを最適化し、ユーザーのニーズに合わせるために重要である。これらは、機械学習応用システムの調整に不可欠であり、人間はシステムの出力を評価し、その解釈を行うことで、初期段階での誤差や不備を識別し、改善に役立てる。中期以降の

段階では、機械による予測や分析の結果を人間が解釈し、それをユーザーに伝える翻訳者としての役割が期待される。この段階では、機械学習応用システムの出力を人間が理解しやすい形で提示することで、機械の提供する情報価値が最大化され、ユーザーのシステムへの信頼が促進される。人間・機械協働において信頼の構築は、中心的な要素であり、5章5節で信頼に至る理由と不信に至る理由及び、5章6節2項で信頼に必要な要素を明らかにしてきた。信頼はユーザーが機械の所作を理解し、受け入れることが重要である。人間と機械が互いに補完し合い、相互適応する双方向のプロセスがあるべき姿であり、人間の直感、知識、解釈能力と機械の計算能力、データ処理能力、予測精度が組み合わせることで、機械学習応用システムはより効果的かつ精密な意思決定を可能にする。人間・機械協働は、機械学習応用システムの深化のあらゆるプロセスで重要な役割を果たす。ここでは機械の出力を翻訳者が解釈を行いユーザーを巻き込んでいく。知識科学の観点では組織の中で人間がいかに関知識活用をしていくかを論じてきたが、人間系を含んだ機械学習応用システムにおける知の創造では、人間と機械間による知識創造プロセスが認められる。

7.3. 理論的貢献

DX3 分類と進化パターン、組機械学習応用システムの深化プロセスの特徴と困難、及び人間・機械協働の理論的貢献について考察する。

DX3 分類と進化パターン

DX3 分類は、1 型（内部チェーン最適化型 DX）から始まり、2 型（バリューチェーン最適化型 DX）、そして 3 型（新事業価値創造型 DX）と進化することを示した。これは、Saldanha(2019)の組織内を対象とした DX とはアクターの対象範囲を協力会社や顧客まで広げた点で異なっている。Iansiti and Lakhani (2020)の AI Factory は対象範囲が協力会社や顧客も含むが、データを元に関企業を AI 化するかが主題でありビジネスモデルの言及は少なく、進化パターンは取り扱っていない。Ismail et al. (2017) は変革の複雑性とインパクトを主題に企業の戦略を DX 文脈で論じた。ただし企業を時系列で捉えて DX の進化パターンには触れていない。DX 文脈での本論文の理論的貢献は DX を行っている企業を時系列で分析しその進化パターンを示したことにある。

人間系を含んだ機械学習応用システムの深化プロセスの特徴と困難

機械学習応用システムの深化プロセスの特徴と困難は企業が DX に取り組む中で、直面する挑戦の一つである。このプロセスはデータ結合プロセス、パイプラインジャングルといった技術的な課題とシステム受容性、ユーザーと機械を取り持つといった人的な課題の両方を含む。機械学習応用システムの成功は、これらの課題を克服し、システムを人間系と機械系のモードを統合する能力が必要である。Porter and Heppelmann(2014)はスマ

ートコネクテッドプロダクトの深化を説き、プロダクトが提供する機能を 4 つに分類した。ただしこの分類には人間系を含んでおらずあくまでもスマートコネクテッドプロダクトの機能的深化を対象としている。Daugherty and Wilson (2018) は人間・機械協働に関する視点を元に人間だけの活動とマシンだけの活動の間の間に存在する概念を提唱した。ただしこの概念にはシステム深化の概念が含まれない。機械学習応用システムの観点で本論文の理論的貢献は人間系を含んだ機械学習応用システムの深化プロセスの特徴と困難を明らかにしたことである。

人間・機械協働

人間と機械の協働は、機械学習応用システム深化の核心を成す。人間の直感、知識、解釈能力と機械の計算能力、データ処理能力、予測精度を組み合わせることで、より精密で効果的な意思決定が可能となる。この協働は、初期段階での機械学習応用システムの調整から、中期・長期的な運用、継続的な深化に至るまで重要な役割を果たす。特に、人間による機械学習応用システムの出力の解釈と翻訳は、システムの精度を高めるとともに、ユーザーのシステム受容性を向上させる上で不可欠である。人間が機械を信用し、人間と機械が互いの能力を補完し合うことで、企業は DX を通じて、新たなビジネス価値を創造し、競争優位を確立することができる。Babic et al. (2021) は機械学習応用システムが現場で受け入れられるための 4 つのステップ、すなわちアシスタントからモニター、コーチ、チームメイトへという提案をしている。本論文の考察でも機械学習応用システムは人間から信頼を獲得することで企業内の参加者として機能すると説いた。Babic et al. (2021) は機械学習応用システムの参加者としての役割を研究の中心においており、機械学習応用システムの深化概念自体には焦点を当てていない。Saenz et al. (2020) は、リスクレベルとプロセスの開示度に基づいて、人間と AI の関係性を述べている。リスクの高低及びプロセスの開示度で人間・機械の競争概念の姿を定義した。ただしこの研究でも同様に機械学習応用システムの深化概念自体には焦点を当てていない。人間・機械協働の観点で、本論文の理論的貢献は機械学習応用システムの深化プロセスに伴い人間・機械の協働がどう変化するかを明らかにしたことである。

7.4. 実務的貢献

DX の観点で企業内のデータに着目し、機械学習応用システムを活用して競争優位を築くことは今後ますます重要となってくる。本研究の実務的貢献は 3 点あげられる。1 点目に DX3 分類と進化パターンを明らかにしたこと。2 点目に DX 実行意思と相関関係の高い要素を明らかにしたこと。3 点目に機械学習応用システムの深化プロセスの特徴と困難及び人間・機械協働の特徴を明らかにしたことである。

DX3 分類と進化パターン

DX を推進するにあたってデジタイゼーションから考えると何を対象にデジタル化するかという視点が含まれていないため困ることが多い。本論文の DX の分類では、バリューチェーンをベースとして必要とされるプロセスを検証の上、デジタル化を推奨する。その特徴と課題をテーマ、コード、サブコードで明らかにしているので参考になるであろう。また業界構造やバリューチェーン構造によってもその進化パターンが異なることも実務的意義がある。

DX 実行意思

本研究で明らかになった DX 実行意思が高い人は DX に対する態度・興味及びスキルや能力に関する自信がある人という分析結果が明らかになった。自分が会社を変えるぞという社員には DX の意義をしっかりと理解してもらい、スキルや能力に関する自信をつけることが有用であることがわかった。これは企業内の人材育成でも参考になるであろう。

機械学習応用システムの深化プロセスの特徴と困難及び人間・機械協働の特徴

機械学習応用システムの深化プロセスでの特徴と困難を明らかにした。これは DX を推進する企業で必須となる、機械学習応用システムが時間をかけて深化、洗練する過程で有用であろう。またその鍵となるのが人間・機械協働である。機械学習応用システムはまだ新しいのでその開発、運用、利用をしてきた人はそれほど多くない。本論文では、人間が機械学習応用システムのパフォーマンスを高めるうえで極めて重要な位置づけとなり、人間に期待される内容を明らかにした。これは今後機械学習応用システムにふれる多くの方にとって人間の良きパートナーとなる機械との接触、対話方法となるため実務的意義がある。

7.5. 本研究の限界と将来研究への示唆

本研究は発展途上のテーマであり、本研究内でもいくつかの限界があり、将来研究の示唆につなげたい。

DX 及び機械学習応用システムのモデル化で実務者へのインタビュー調査によりデータコレクションし、その結果をテーマティック・アナリシス法で分析した。インタビュー対象者の選定においてはなるべく業界やバリューチェーンを分散してサンプリングを実施したが、サンプル数からある一定のバイアスがかかっていると推察できる。そのため今後は事例研究対象を増やし理論の補強を行うことが望ましい。

全体を通して、本論文で提示しているモデルの有用性検証も将来研究として価値がある。ツール化できていない点も限界の一つであり、DX や機械学習応用システムの深化、人

間機械協働のパターンは把握できたが、実務的に用いやすくするためには、具体的な設計手法やフレームワークが必要である。例えば、人間・機械協働の GQM+Strategies や機械学習応用システムの深化のロードマッピング手法などが考えられる。

人間・機械協働においては、本研究では翻訳者の存在は論理的に導き出せるものの、翻訳者自身へのインタビューを行っていないため、どのような思考、意思決定をしているかはデータがそろっておらず言及ができない。これも一つの限界として挙げられる。また、機械学習応用システムを人間がいかに受容するかを認知科学的な観点からモデル化するなどの研究分野が考えられる。

DX 分類と機械学習応用システムの深化の共進化について、本研究では考察で言及をしているものの、データとしては不十分である。そのため DX 観点と機械学習観点どちらがより進化のイニシアチブをとっていくかを事例研究的アプローチで共進化のモデル化や因子の分析を行うことに研究余地がある。

AI はこの数年技術進歩が著しく、人間らしさを追求したヒューマノイドロボットや人間映像を元にしたインターフェース、動画の動的生成、人間との感情的つながりを有するチャットボットやロボットなど様々なプロダクトが出現するであろう。人間・機械の関係性をヒューマンマシンチームングやヒューマンマシンコラボレーションの観点で分析可能であり、今後も継続的に研究テーマは出現するであろう。

以上の限界を踏まえ、今後の研究ではこれらの課題を克服するための取り組みが求められる。具体的には、翻訳者や実務者への更なるインタビュー調査を行い理論の補強を図ること、具体的な設計手法やフレームワークを開発し実務での有用性を検証すること、そして多様な形態の AI と人間との協働をさらにモデル化することが重要である。

参考文献

- Agrawal, P., and Narain, R., 2018, "Digital supply chain management: An Overview. In IOP conference series: materials science and engineering", *IOP Publishing*, Vol. 455(1): 012074.
- Ajzen, I., 1991, "The theory of planned behavior", *Organizational behavior and human decision processes*, 50(2):179-211.
- Amershi, S. et al., 2019, "Software Engineering for Machine Learning: A Case Study", *Proc. 2019 IEEE/ACM 41st Int. Conf. Softw. Eng. Pract. ICSE-SEIP*, 2019: 291-300.
- Appio, F. P., Frattini, F., Petruzzelli, A. M., and Neirotti, P., 2021, "Digital transformation and innovation management: A synthesis of existing research and an agenda for future studies", *Journal of Product Innovation Management*, 38(1): 4-20.
- Babic, B. et al., 2020, "A better way to onboard AI", *Harvard Business Review*, 2020 July- August.
- Balaji, S., and Murugaiyan, 2012, "Waterfall vs. V-Model vs. Agile: A comparative study on SDLC", *International Journal of Information Technology and Business Management*, 2(1):26-30.
- Bosch, K. V. D. and Bronkhorst, A., 2018, "Human-AI cooperation to benefit military decision making", *STO June*: 1-12.
- Boyatzis, R. E., 1998, "Transforming Qualitative Information: Thematic Analysis and Code Development", *SAGE Publications*.
- Daugherty, P. R. and Wilson, H. J., 2018, "Human+ machine: Reimagining work in the age of AI", *Harvard Business Press*.
- DeStefano T. , "2023, People may be more trusting of AI when they can't see how it works", *HBR September-October 2023*.
- Dorf, B., Blank, S., 2020, *The Start-up Owner's Manual: The Step-By-Step Guide for Building a Great Company*, United States: Wiley.
- Fayyad, U., Piatetsky-Shapiro, G. and Smyth, P., 1996, "The KDD Process for Extracting Useful Knowledge from Volumes of Data", *Communications of the ACM*, 39-11: 27-34.
- Fereday, J. and Muir-Cochrane, E., 2006, "Demonstrating rigor using thematic analysis: A hybrid approach of inductive and deductive coding and theme development", *International journal of qualitative methods*, 5(1): 80-92.
- Frank, A. G., Dalenogare, L. S. and Ayala N. F., 2019, "Industry 4.0 technologies: Implementation patterns in manufacturing companies", *International Journal of Production Economics*.

- Furr, N. and Shipilov, A., 2019, “Digital doesn’t have to be disruptive: the best results can come from adaptation rather than reinvention”, *Harvard Business Review*, 97(4).
- Gamma E, Richard H, Ralph J, and John V, 1994, *Design Patterns: Elements of Reusable Object-Oriented Software*, Addison-Wesley Professional. (本位田真一・吉田和樹訳, 1995, 『オブジェクト指向における再利用のためのデザインパターン』, ソフトバンク.)
- Gefen, D., Karahanna, E., & Straub, D. W., 2003, “Trust and TAM in online shopping: An integrated model”, *MIS quarterly*, 51-90.
- Govindarajan, V., and Immelt, JR, 2019, “The only way manufacturers can survive”, *MIT Sloan Management Review*, 60(3): 24-33.
- Haaker, T., Ly, P. T. M., Nguyen-Thanh, N., and Nguyen, H. T. H., 2021, “Business model innovation through the application of the Internet-of-Things: A comparative analysis”, *Journal of Business Research*, 126-136.
- Iansiti, M., and Lakhani, K. R., 2020, *Competing in the age of AI: Strategy and leadership when algorithms and networks run the world*, Massachusetts: Harvard Business Press.
- Ibarra, D., Ganzarain, J., and Igartua, JI, 2018, “Business model innovation through Industry 4.0: A review”, *Procedia manufacturing*, 22: 4-10.
- Ismail, MH, Khater, M., & Zaki, M., 2017, “Digital Business Transformation and Strategy: What Do We Know So Far?”, *Cambridge Service Alliance*.
- Jordan, M. I., and Mitchell, T. M., 2015, “Machine learning: Trends, perspectives, and prospects”, *Science*, 349(6245): 255-260.
- Lee, J. D., & See, K. A., 2004, “Trust in Automation: Designing for Appropriate Reliance”, *Human Factors*, 46(1): 50-80.
- Lin, H., et al., 2024, “Machine learning and human-machine trust in healthcare: a systematic survey”, *CAAI Trans. Intell. Technol.* 9(2):286-302.
- Matthew, J. and Alonso, H. V., 2019, “No Ai is an island: The case for teaming intelligence”, *AI Magazine*, 40(1): 16-28.
- McGrath, R. and McManus, R., 2020, “Discovery-Driven Digital Transformation”, *Harvard Business Review*, 98(3): 124-133.
- McIntosh, M. J. and Morse, J. M., 2015, “Situating and constructing diversity in semi-structured interviews”, *Global Qualitative Nursing Research*. Res. 2.
- Müller, J. M., Buliga, O., and Voigt, K. I., 2018, “Fortune favors the prepared: How SMEs approach business model innovations in Industry 4.0”, *Technological Forecasting and Social Change*, 132: 2-17.

- Nahar, N., Zhou, S., Lewis, G., and Kästner, C., 2022, "Collaboration challenges in building ml-enabled systems: Communication, documentation, engineering, and process" *In Proceedings of the 44th International Conference on Software Engineering*, 413-425.
- Nahar, N., Zhou, S., Lewis, G., and Kästner, C., 2022, "Collaboration challenges in building ml-enabled systems: Communication, documentation, engineering, and process" , *In Proceedings of the 44th International Conference on Software Engineering*, 413-425.
- Nonaka, I. & Takeuchi, H., 1995,, The Knowledge-Creating Company, *Oxford Univ Pr.*
- O' Reilly III, C. A., and Tushman, M. L., 2021, "Lead and disrupt: How to solve the innovator's dilemma" , Stanford University Press.
- Osterwalder A. and Pigneur Y., 2010, "Business model generation: a handbook for visionaries, game changers, and challengers" , *John Wiley & Sons*.
- Pan, Y., 2016, "Heading toward artificial intelligence 2.0" , *Engineering 2*, 2016: 409-413.
- Porter, M. E., 2001, "The value chain and competitive advantage" , *Understanding business processes*, 2, 50-66.
- Porter, ME, and Heppelmann, JE, 2014, "How smart, connected products are transforming competition" , *Harvard Business Review*, November.
- Riccio, V., Jahangirova, G., and Stocco, A. et al., 2020, "Testing machine learning based systems: a systematic mapping" , *Empir Software Eng*, 25: 5193-5254.
- Ries, E., 2011, *The lean startup: How today's entrepreneurs use continuous innovation to create radically successful businesses*. Crown Currency.
- Royce W., 1970, "Managing the development of large-scale systems" , *Mathematics and Computers in Simulation*, 33(4): 287-293.
- Saenz, M. J., Revilla, E. and Simón, C., 2020, "Designing AI Systems With Human-Machine Teams" , *MIT SLOAN MANAGEMENT REVIEW*.
- Saldanha, T., 2019, *Why digital transformations fail: The surprising disciplines of how to take off and stay ahead*. Berrett-Koehler Publishers.
- Sculley, D. et al., 2015, "Hidden technical debt in machine learning systems" , *Advances in Neural Information Processing Systems*, 2015-January: 2503-2511.
- Sebastian, I, R., JW, B. C., Mocker, M., Moloney, KG. and Fonstad, NO., 2020 "How big old companies navigate digital transformation" , *Strategic information management*, Routledge, :133-150.
- Siau, K., & Wang, W., 2018, "Building trust in artificial intelligence, machine learning, and robotics" , *Cutter business technology journal*, 31(2):47-53.

- Sjödén, D., Parida, V., Palmié, M., and Wincent, J., 2021, “How AI capabilities enable business model innovation: Scaling AI through co-evolutionary processes and feedback loops” . *Journal of Business Research*, 134, 574–587.
- Stolterman, E., and Fors, AC., 2004, “Information technology and the good life” , *Information systems research*, Springer, :687–692.
- Takeuchi, H. & Nonaka, I., 1986, “The New New Product Development Game” , *Harvard Business Review*, 64(1): 137–146.
- Uchihira, N., 2022, “Success Mechanisms of Smart Factories in Small and Medium-Sized Enterprises” , *2022 IEEE Technology & Engineering Management Conference - Asia Pacific (TEMSCON-ASPAC)*, :067–074.
- Vrana, J., and Singh, R., 2021, “Digitization, digitalization, and digital transformation” , *Handbook of Nondestructive Evaluation 4.0*, : 1–17.
- Washizaki, H., Khomh, F., Gueheneuc, Y., Takeuchi, H., Natori, N., Doi, T., Okuda, S., 2022, “Software-Engineering Design Patterns for Machine Learning Applications” , *IEEE Computer*, 55(3): 30–39.
- Watanabe, Y., Washizaki, H., Sakamoto, K., Saito, D., Honda, K., Tsuda, N., Fukazawa, Y. and Yoshioka, N., 2019, “Preliminary Systematic Literature Review of Machine Learning System Development Process” .
- Microsoft, “What is the Team Data Science Process?” , learn. Microsoft, Washington: Microsoft corporation, Retrieved November 18, 2022, <https://learn.microsoft.com/en-us/azure/architecture/data-science-process/overview>).
- Wirth, R. and Hipp, J., 2000, “CRISP-DM: Towards a standard process model for data mining” . *Proceedings of the 4th International Conference on the Practical Applications of Knowledge Discovery and Data Mining*.
- Yang, Q., Steinfeld, A., Rosé, C. and Zimmerman, J., 2020, “Re-examining Whether, Why, and How Human-AI Interaction Is Uniquely Difficult to Design” , Conference on Human Factors in Computing Systems. Proc: 1–13.
- 内平直志, 2021, 「機械学習応用システム開発における課題・ニーズマップ」, 北陸先端科学技術大学院大学内平研究室, (2021年2月2日取得, <http://www.jaist.ac.jp/ks/labs/uchihira/mlas-pm-map.html?fbclid=IwAR3cmA0f11KD7gGRyFgmafdQ1C5VYpxCvv8XBSMvGxko7D0xaajoqsK8PwiE>)
- 江間有沙・秋谷直矩・大澤博隆・服部宏充・大家慎也・市瀬龍太郎・神崎宣次・久木田水生・西條玲奈・大谷卓史・宮野公樹・八代嘉美, 2016, 「運転・育児・防災活動, どこまで機械に 任せるか 多様なステークホルダーへのアンケート調査」 『Journal of Information Processing and Management』, 59(5): 322–330.

- 大野豊, 1987, 「ソフトウェア工学の背景と展望」『情報処理』28(7):845-852.
- 奥田聡・更田誠・大江建, 2021, 「中小ものづくり企業の生き残り戦略—株式会社浜野製作所の産学連携応用と両利きの経営の実現事例—」『日本ベンチャー学会誌』37:小西葉子・本村陽一, 2017, 「AI技術の社会実装への取り組みと課題—産総研aiプロジェクトから学ぶ」, REITIホームページ, (2020年12月28日取得, <https://www.rieti.go.jp/jp/publications/summary/17030044.html>).
- 小倉孝裕, 2023, 「複数目的・複数主体からなる多段階在庫配置問題の意思決定における人と機械の協働プロセス」, 北陸先端科学技術大学院大学博士論文.
- 白坂一, 2021, 「AIと弁理士の協働による進歩性判断—先行特許文献調査システムの発明現場への導入—」, 北陸先端科学技術大学院大学博士論文.
- 総務省, 2020, 「情報通信白書」, 総務省, (2024年5月11日取得, <https://www.soumu.go.jp/johotsusintokei/whitepaper/ja/r02/html/nd252150.html>).
- 玉井哲雄, 2008, 「ソフトウェア工学の40年」『情報処理』49(7): 777-784.
- 田路則子・鹿住倫世・新谷優・本條晴一郎, 2018, 「大学生の起業意識調査レポート—GUESS2016 調査結果における日本のサンプル分析—」『イノベーション・マネジメント』15:109-129.
- 田中裕子・久保裕史, 2018, 「人工知能を活用した業務自動化における P2M 理論の適用」『Journal of International Association of P2M』12(2): 1-16.
- 野中郁次郎・竹内弘高, 2020, 『ワイズカンパニー—知識創造から知識実践への新しいモデル』東洋経済.
- 独立行政法人情報処理推進機構, 2023, 「DX白書2023」, 独立行政法人情報処理推進機構, (2024年5月17日取得, <https://www.ipa.go.jp/publish/wp-dx/gmcbt8000000botk-att/000108041.pdf>).
- 独立行政法人情報処理推進機構, 2023, 「トランスフォーメーションに対応するためのパターン・ランゲージ (略称トラパタ)」, 独立行政法人情報処理推進機構, (2024年3月23日取得, <https://www.ipa.go.jp/jinzai/skill-transformation/henkaku/torapata.html>).
- 平鍋健児・野中郁次郎, 2013, 『アジャイル開発とスクラム 顧客・技術・経営をつなぐ協調的ソフトウェア開発マネジメント』翔泳社.
- 丸山宏, 2017, 「機械学習工学に向けて」『日本ソフトウェア科学会第34回大会(2017年度)講演論文集. 日本ソフトウェア科学会』.
- 森俊樹, 2020, 「リスクマネジメントにおける機械学習と知識創造の統合アプローチ—機械参加型 (machine-in-the-loop) プロセスの提案—」, 北陸先端科学技術大学院大学博士論文.
- 吉岡信和, 2018, 「機械学習工学: 4. 機械学習応用システムのセキュリティとプライバシー」『情報処理』60(1): 34-39.
- 鷺崎弘宜, 2011, 「—時を超えるソフトウェアの道— 1」『情報処理』52(9): 1119-1126.

備考

A1.3 章コードシステム

3章のインタビュー結果をまとめた際のコードシステムは以下の通りである。

付表 A1 3 章コードシステム

コードシステム			
コードシステム			
	DX classification		
		1型	
		できるところから始める	
		当事者としての問題意識	
		まずはデータを集める	
		デジタルプラットフォーム活用	
		データ活用のためのシステム基盤構築	
		データ価値の探索	
		局所最適から社内全体へ	
		局所的な成功体験を実績として活用	
		前後プロセスへの広がり	
		2型	
		自社の仕組に協力会社まきこむ	
		結果の見える化推進	
		新たな協力関係	
		データを基にした付加価値向上	
		試行錯誤	
		社外向け付加価値	
		顧客を巻きこむ	
		顧客への情報開示	
		エンパワーメント	
		3型	
		探索型アプローチ	
		M&Aきっかけ	
		外部パートナー	
		ビジネスモデル変革	
		既存データからの新規商品・サービスはいはt津	
		課金システムの変更	
		1型, 2型からのデータ活用	
		データから得る多様な付加価値	
		多様な価値提案による顧客セグメントの拡張	

A2.3 章インタビューデータとコード

3 章のインタビュー結果をテーマティック・アナリシス法により切片化とコーディングを行った結果を以下に示す。切片番号はインタビュー対象者一番号の割り付けにより一意にナンバリングを行っている。

付表 A2 3 章インタビューデータとコード

切片番号	インタビューデータ	コード
2-1	私がコンビニの店長をやっていたのは 18 年ほど前になりますが、この時から、「現場の仕事は宝の山なのにそれが放置されている」という強い問題意識がありました-中略- 弊社は覆面調査というビジネスで起業しましたが、データは蓄積すれば価値になるはずだ、と思って「サービス A」という店舗の情報をデータベース化する仕組みというのを最初から構築していました。それが、やっとここ 2〜3 年で価値として認められてきた、ということです。	1 型一できることから始める
7-1	デジタル知見上手く活用してデジタル集客のレバーをかけたりデータを活用したり生産性を改善したり営業マンをデータドリブンにしたり。(ということをやってきた)	1 型一できることから始める
3-1	東日本大震災が発生した時、従来のマスメディアでは地域別の詳細な情報が伝わってこなかったため、Twitter を見ていると「ここには物資が不足している」とか「ここでボランティアを探している」といったツイートがかなりありました。当時は Twitter ユーザーはそれほど多くありませんでしたが、この情報を整理し、地域別にまとめると役に立つだろうと思いました。これがビジネスの出発点でした。現在では、会社は SNS だけでなく、気象データ、カーナビゲーションシステムからの走行データ、人流データ、衛星データなどを組み合わせてデータ分析を行っています。	1 型一できることから始める
3-2	もう一つ実証実験中のプロジェクトを紹介しますと、冬場に起きる道路のスタック（車両滞留）の被害を未然に察知するシステムの開発です。道路に設置されているカメラや車のデータなどを使って、積雪の深さなどの道路の路面の状態や、吹雪やホワイトアウトと言ったものを自動判定しようというものです。カメラは道路会社や国土交通省、各自治体が設置しているカメラが全国無数にありますので、これを活かすことになります。	1 型一デジタルプラットフォーム活用
1-1	当社は EC でするので、ウェブサイト上のお客様の行動やレビュー、Twitter 等の SNS で世の中の状況を常に分析しています。	1 型一デジタルプラットフォーム活用
6-1	全車両に搭載したのが今年の 4 月、実用化まで 1 年の実証実験を繰り返しました。最初は 30 台のタブレットと、選抜された 60 名のドライバーからスタートして、さらに 3 か月後に 50 台、100 台、500 台と増やしながら進めていきまし	1 型一局所最適から社内全体へ

	た	
1-2	商品の選定から発注入荷や出荷輸送配送といった全てのプロセスを俯瞰して、最適化を図っていくというのが物流 DX としては非常に重要かと思います。データについても、元々ある色々なデータをお客様基盤中心に統合しつつ、何が問題になっているのか、何をしたら全体がよくなるのかという分析をしながら、プラットフォーム全体を進化させていくということ	1 型一局所最適から社内全体へ
1-3	私たちはスタートアップ段階からデータドリブン指向のビジネスモデルを構成しています。そのため、旧来の企業と比べて部門間のサイロ問題は発生していません。私たちは購買ロジスティクス、在庫管理、出荷ロジスティクスなど多くのプロセスでデータドリブン最適化を実現しています。上記の背景から 1 型はスムーズにスタートしました。サプライヤーの在庫情報を統合することで在庫切れを防ぎ、利用者の利便性の向上と売上の増加を実現できます。適切な在庫配置と出荷ロジスティクスの最適化には大量のデータが必要であり、それらは機械学習応用システムによって自律的に運用されています。	2 型一協力会社を巻き込む
6-2	売上への効果も、アプリを起動している状態では起動していない状態に比べ、6.8%伸びたというデータがでています。機能別に売上効果を見ると、「高需要エリア検索」機能を使った場合、ベテランですと 5.2%、新人では 16.6%売上が上がっています。電車が運休になったりした時に出る「特需通知閲覧」ですが、こちらはベテランも新人も閲覧したドライバーは閲覧しなかったドライバーに比べ 10%ほど売上が伸びている。「イベント情報閲覧」ではベテランと新人では売上増効果に差が出ておりますが、これはベテランドライバーの方がイベント会場がどこにあるかとかが分かっているのです、その差かなと思っています。	2 型一協力会社を巻き込む
2-2	顧客であるメーカーに対して、例えばこういう商品を展開する時にどこの店舗で販促を強化すれば効果的です、とか、商品のターゲットとする客層が多い店舗はここですよ、という提案をしながら、(販促を強化すべき)店舗リストを無償で提供する代わりに、弊社のデジタルサイネージを導入してください、ラウンダーのサービスを導入してください、販売員の派遣をさせてください、というような営業活動に繋げる、ということを行っています。	2 型一顧客を巻き込む
4-1	顧客であるサービスの導入者側の運用者様を、AI でエンパワーメントする、という考え方です。これは我々や我々の AI が運用者様にとって代わるというものではなくて、運用者様に判断の為の情報を与えるだとか、AI が新規のディレクションに関してもルールだけ作って、あとは適用するかしないかは人にお任せするというような状態で持っていく、という業務効率化です。	2 型一顧客を巻き込む

8-1	問題はユーザー情報の取得が難しいことでした。小売販売を通じて靴を販売しているため、ユーザーが製品をどのように使用しているかを知ることができませんでした。ランナーアプリを取得することでランナーコミュニティへのパスを作りました。アプリケーションを含むランナーエコシステムの構築というビジョンを持ってビジネスを推進しています。	2 型—顧客を巻き込む
8-2	いわゆるビッグデータという考え方もあると思いますし、ビッグデータから学んだものを築き、どういう風にパーソナライズして提供していくかというのが大事なと思っています。この付加価値をどのように付けるかという、1つの ID に紐づけることによってデータを分析できるようにする、というところが今我々が始めたところです。今まで色々なサービスを提供していましたが、それぞれが別々の ID でログインしなきゃいけなくて、裏のデータベースが連携していなかった状態だったのを、サービス A というシングル ID メンバーシップサービスをすることによってデータがやっとデータウェアハウスに溜まり始めてきたという状況です。 —中略— 今まで当社はアスリートたちへのサポート、特にパフォーマンスアスリートのためのビジネスを中心に展開してきましたが、今後はより広い視野での事業への拡大をしていきたいと考えています。今まではパフォーマンスアスリートでした。 今後 2030 年に向けて VISION2030 を作り、“Lifetime Athletes in All of Us” というモットーで、誰もが一生涯スポーツに関わる心と、身体が健康でい続けられる世界を実現したいということでこのメッセージを掲げています。	2 型—データを基にした付加価値向上
4-2	まず 1 つ目が、専任者のナレッジ・スキルに再現性を持たせ、レバレッジを効かせる、ということです。具体的には、我々はセキュリティサービスを展開している会社で、顧客を担当する者にそれなりの専門性が求められます。しかしその専門性というものは多岐に渡っていて、すべての分野の専門家をすべての顧客に張り付かせるレベルで確保するのは現実的に不可能です。そこで我々は AI でそれぞれの専門家のナレッジ・スキルを再現できるようにして、担当者がカバーできる領域を増やしています。専門性をコモディティ化している、ともいえるでしょう。	2 型—データを基にした付加価値向上
6-3	タクシー事業のビジネス特性上、ベテランドライバーと新人ドライバーの売上の差は顕著です。また、タクシーの運転方法はベテランドライバーの暗黙知に蓄積されており、新人に容易に伝えることができませんでした。会社はタクシーの移動情報をデータベースに蓄積し、売上の高いドライバーの特性を調査し、新人ドライバー向けのナビゲーションシステムとして提供しました。これは、エリア検索機能を使用した新人ドライバーに比べて 1.6%の売上増加と、詳細な需要情報の閲覧による 1.9%の売上増加に寄与しまし	3 型—1 型、2 型からのデータ活用

	た。現在は他の会社にも提供しています。	
4-3	何をデジタル／AI 化し、何を人がやって、何が人にしかできないかというところをちゃんと明確化する。そして人がやらなくてもいいこと、人が得意ではないことに関してはデジタル／AI 化することで、人をエンパワーメントしていく。つまり、人がやらなくてはいけないことに人が集中する世界が「DX が進んだ世界」なんじゃないかな、と個人的に思います。	3 型ー1 型、2 型からのデータ活用
2-3	私たちは営業スタッフを通じてどの店舗でどのくらいの製品が売れたかのデータをまとめています。その結果、COVID-19 対応の一環として、営業スタッフ派遣型からデジタルサイネージを使用したプロモーションにシフトしました。過去のデータから、どの販売フロアがデジタルサイネージによって結果につながるかを予測する強みがあります。データによる予測デジタルサイネージビジネスを迅速に立ち上げることを可能にしました。	3 型ービジネスモデル変革
6-4	続いて 3 つ目のビジネスモデル「移動時間を、体験時間に」ということで、さらに広告の価値を上げるサービスをご説明します。これはディズニープラスさんと昨年実施したディズニープラスタクシーというサービスです。 ー中略ー SNS 上の反響も非常に好意的でした。インフルエンサーからは「100 台しかない奇跡のタクシーに乗れた」、「車内のシートもディズニー仕様でかわいい」といった投稿、そして一般ユーザーからも「ディズニープラスタクシー 2 種類ゲット」や「美女と野獣のマーブル仕様に乗れた、ラッキー」など沢山の画像も上がり、クライアントのディズニープラスさんも反響の大きさに驚いていたようです。この広告はテレビは雑誌の広告と違い、広告を見た人の反応効果をタイムリーに確認できるので、新しい広告ビジネスの可能性を感じております。今後は 100 台からさらに拡大していく予定です。	3 型ービジネスモデル変革
2-4	2012 年に上場してから販促の領域で M&A をしたり、新会社を設立したりで、今は子会社 10 社とグループを形成しています。デジタルサイネージ事業も、M&A した会社が M&A 以前から長く行っていた事業なのです。	3 型ー探索型アプローチ

6-5	弊社 1 社で進めていくものもあれば、先ほど申し上げた通り、資本金も出してサービス A 会社の枠組みの中で進めていくものと、AI の分科会、広告の分科会、タブレットの分科会、マーケティングの分科会と毎週メンバーが決まって議論して新しいビジネスモデルを作っていますので、弊社としては自社で進めるものと（サービス A 社の）枠の中でやるものと、どちらにしてもチャレンジ精神を持って進めて行きたいと思っています。	3 型一探索型アプローチ
5-1	会社（顧客企業）の中で使っている人と・使っていない人（ベテラン）が分かれている。そのためカスタマーサクセス部署を作って、ZOOM で使い方をオンラインで教えたりしている。	3 型一探索型アプローチ

B1.4 章 2 節アンケート項目

付表 B1 4 章 2 節アンケート項目

設問	選択肢
プログラムの雰囲気は DX のアイデア創出を促してくれることを強く期待している。	まったくその通り = 7 ～どちらとも言えない = 4 ～まったく違う = 1
プログラムに、事業変革者を生む好ましい雰囲気があることを強く期待している。（「事業変革者」とは、「DX を通じて事業の仕組みを変えたり、新しい事業を生み出す人」と捉えてください。以下同じ。）	まったくその通り = 7 ～どちらとも言えない = 4 ～まったく違う = 1
プログラムが事業変革者的な活動をすることを後押ししてくれることを強く期待している。	まったくその通り = 7 ～どちらとも言えない = 4 ～まったく違う = 1
プログラムから自身へ与えられた結果（コンペティション：順位、講義：フィードバック）に満足できることを強く期待している。	まったくその通り = 7 ～どちらとも言えない = 4 ～まったく違う = 1
プログラムは、私の事業変革者としての姿勢、価値観、モチベーションに関する理解を深めてくれることを強く期待している。	まったくその通り = 7 ～どちらとも言えない = 4 ～まったく違う = 1
プログラムが私にとって、事業変革を始めるために取るべき行動に関する理解を深めてくれることを強く期待している。	まったくその通り = 7 ～どちらとも言えない = 4 ～まったく違う = 1
プログラムが 私にとって、事業変革を始めるための実践的スキルを高めてくれることを強く期待している。	まったくその通り = 7 ～どちらとも言えない = 4 ～まったく違う = 1
プログラムが 私にとって、ネットワークを広げていく能力を高めてくれることを強く期待している。	まったくその通り = 7 ～どちらとも言えない = 4 ～まったく違う = 1
プログラムが 私にとって、ビジネスチャンスを発見する能力を高めてくれることを強く期待している。	まったくその通り = 7 ～どちらとも言えない = 4 ～まったく違う = 1

	う = 1
事業変革者になることは自分にとってデメリットよりもメリットのほうが大きい	まったくその通り = 7 ~ どちらとも言えない = 4 ~ まったく違う = 1
事業変革者というキャリアは魅力的である	まったくその通り = 7 ~ どちらとも言えない = 4 ~ まったく違う = 1
機会や資金などの会社からのリソースさえあれば事業変革者になる	まったくその通り = 7 ~ どちらとも言えない = 4 ~ まったく違う = 1
事業変革者になることは自分に大きな満足をもたらす	まったくその通り = 7 ~ どちらとも言えない = 4 ~ まったく違う = 1
様々な選択肢がある中で私はあえて事業変革者になることを選びたい	まったくその通り = 7 ~ どちらとも言えない = 4 ~ まったく違う = 1
あなたの家族	まったくその通り = 7 ~ どちらとも言えない = 4 ~ まったく違う = 1
あなたの友人	まったくその通り = 7 ~ どちらとも言えない = 4 ~ まったく違う = 1
会社の同僚	まったくその通り = 7 ~ どちらとも言えない = 4 ~ まったく違う = 1
プログラムで出会うメンター・講師・受講生	まったくその通り = 7 ~ どちらとも言えない = 4 ~ まったく違う = 1
私はいつも利益を守ることができる（注：損をする取引を回避する）	まったくその通り = 7 ~ どちらとも言えない = 4 ~ まったく違う = 1
私は計画を作るときは、ほぼ実現させるようにする	まったくその通り = 7 ~ どちらとも言えない = 4 ~ まったく違う = 1
私は自分の人生に起きることを自分の責任としてとらえることができる	まったくその通り = 7 ~ どちらとも言えない = 4 ~ まったく違う = 1
常に新しいことをやるタイプである	まったくその通り = 7 ~ どちらとも言えない = 4 ~ まったく違う = 1
新商品や新サービスを創出することが得意である	まったくその通り = 7 ~ どちらとも言えない = 4 ~ まったく違う = 1
創造性を発揮することが得意である	まったくその通り = 7 ~ どちらとも言えない = 4 ~ まったく違う = 1

イノベーションを管理することが得意である	まったくその通り = 7 ～どちらとも言えない=4～まったく違う = 1
リーダーやまとめ役になるのが得意である	まったくその通り = 7 ～どちらとも言えない=4～まったく違う = 1
専門家のネットワークを作るのが得意である	まったくその通り = 7 ～どちらとも言えない=4～まったく違う = 1
新しいアイデアを事業化するのが得意である	まったくその通り = 7 ～どちらとも言えない=4～まったく違う = 1
事業を成功させる自信がある	まったくその通り = 7 ～どちらとも言えない=4～まったく違う = 1
事業変革者になる準備はできている	まったくその通り = 7 ～どちらとも言えない=4～まったく違う = 1
職業上の目標は事業変革者である	まったくその通り = 7 ～どちらとも言えない=4～まったく違う = 1
事業変革をするためならどんな努力も惜しまない	まったくその通り = 7 ～どちらとも言えない=4～まったく違う = 1
私は将来事業変革をすると決めている	まったくその通り = 7 ～どちらとも言えない=4～まったく違う = 1
私はかなり真剣に事業変革をすることを考えている	まったくその通り = 7 ～どちらとも言えない=4～まったく違う = 1
私はプロフェッショナルとしていくつもの事業変革を行いたいと強く思っている	まったくその通り = 7 ～どちらとも言えない=4～まったく違う = 1
私はビジネス・マネジメント力に長けていると思う（投資判断力・経営資源分配力・ビジョン策定力）	まったくその通り = 7 ～どちらとも言えない=4～まったく違う = 1
私は事業環境洞察力に長けていると思う（環境変化感知力・将来動向洞察力・シナリオプランニング力）	まったくその通り = 7 ～どちらとも言えない=4～まったく違う = 1
私は組織けん引力に長けていると思う（巻き込み力・リーダーシップ力・やり抜く力）	まったくその通り = 7 ～どちらとも言えない=4～まったく違う = 1
私は着想力に長けていると思う（情報収集・分析力・アイデア発想力・コンセプト力）	まったくその通り = 7 ～どちらとも言えない=4～まったく違う = 1
私は企画構築力に長けていると思う（企画力・デザイン力・コーディネート力）	まったくその通り = 7 ～どちらとも言えない=4～まったく違う = 1

	う = 1
私はコミュニケーション力に長けていると思う（引き出し力・ファシリテーション力・合意形成力）	まったくその通り = 7 ～どちらとも言えない=4～まったく違う = 1
私はリサーチ力に長けていると思う（先進技術情報収集力、技術吸収力、技術伝播力）	まったくその通り = 7 ～どちらとも言えない=4～まったく違う = 1
私は技術伝播力に長けていると思う（適用技術評価力、ブランドデザイン力、適用検証力）	まったくその通り = 7 ～どちらとも言えない=4～まったく違う = 1
私は実践力に長けていると思う（アイデア具現化力、試作・改善力、技術応用力）	まったくその通り = 7 ～どちらとも言えない=4～まったく違う = 1
私はデザイン思考力に長けていると思う	まったくその通り = 7 ～どちらとも言えない=4～まったく違う = 1
私はリーンスタートアップ的な思考・行動に長けていると思う	まったくその通り = 7 ～どちらとも言えない=4～まったく違う = 1
私はアジャイル的な思考・行動に長けていると思う	まったくその通り = 7 ～どちらとも言えない=4～まったく違う = 1
私は情報発信力に長けていると思う	まったくその通り = 7 ～どちらとも言えない=4～まったく違う = 1
未来妄想力自身の中に在るか？	まったくその通り = 7 ～どちらとも言えない=4～まったく違う = 1
未来妄想力組織の中に在るか？	まったくその通り = 7 ～どちらとも言えない=4～まったく違う = 1
社会課題は未来の芽自身の中に在るか？	まったくその通り = 7 ～どちらとも言えない=4～まったく違う = 1
社会課題は未来の芽組織の中に在るか？	まったくその通り = 7 ～どちらとも言えない=4～まったく違う = 1
未来への羅針盤自身の中に在るか？	まったくその通り = 7 ～どちらとも言えない=4～まったく違う = 1
未来への羅針盤組織の中に在るか？	まったくその通り = 7 ～どちらとも言えない=4～まったく違う = 1
価値創造のためのシナリオ自身の中に在るか？	まったくその通り = 7 ～どちらとも言えない=4～まったく違う = 1

価値創造のためのシナリオ組織の中に在るか？	まったくその通り = 7 ～どちらとも言えない=4～まったく違う = 1
枠を外して考える自身の中に在るか？	まったくその通り = 7 ～どちらとも言えない=4～まったく違う = 1
枠を外して考える組織の中に在るか？	まったくその通り = 7 ～どちらとも言えない=4～まったく違う = 1
実現のためのあらゆる可能性自身の中に在るか？	まったくその通り = 7 ～どちらとも言えない=4～まったく違う = 1
実現のためのあらゆる可能性組織の中に在るか？	まったくその通り = 7 ～どちらとも言えない=4～まったく違う = 1
顧客も知らない顧客自身の中に在るか？	まったくその通り = 7 ～どちらとも言えない=4～まったく違う = 1
顧客も知らない顧客組織の中に在るか？	まったくその通り = 7 ～どちらとも言えない=4～まったく違う = 1
共感発信から自身の中に在るか？	まったくその通り = 7 ～どちらとも言えない=4～まったく違う = 1
共感発信から組織の中に在るか？	まったくその通り = 7 ～どちらとも言えない=4～まったく違う = 1
データに価値を語らせる自身の中に在るか？	まったくその通り = 7 ～どちらとも言えない=4～まったく違う = 1
データに価値を語らせる組織の中に在るか？	まったくその通り = 7 ～どちらとも言えない=4～まったく違う = 1
未知を力に自身の中に在るか？	まったくその通り = 7 ～どちらとも言えない=4～まったく違う = 1
未知を力に組織の中に在るか？	まったくその通り = 7 ～どちらとも言えない=4～まったく違う = 1
常にアップデート自身の中に在るか？	まったくその通り = 7 ～どちらとも言えない=4～まったく違う = 1
常にアップデート組織の中に在るか？	まったくその通り = 7 ～どちらとも言えない=4～まったく違う = 1
多文化の架け橋自身の中に在るか？	まったくその通り = 7 ～どちらとも言えない=4～まったく違う = 1

	う = 1
多文化の架け橋組織の中に在るか？	まったくその通り = 7 ～どちらとも言えない=4～まったく違う = 1
チャレンジ特区自身の中に在るか？	まったくその通り = 7 ～どちらとも言えない=4～まったく違う = 1
チャレンジ特区組織の中に在るか？	まったくその通り = 7 ～どちらとも言えない=4～まったく違う = 1
適時適任自身の中に在るか？	まったくその通り = 7 ～どちらとも言えない=4～まったく違う = 1
適時適任組織の中に在るか？	まったくその通り = 7 ～どちらとも言えない=4～まったく違う = 1
高速仮説検証サイクル自身の中に在るか？	まったくその通り = 7 ～どちらとも言えない=4～まったく違う = 1
高速仮説検証サイクル組織の中に在るか？	まったくその通り = 7 ～どちらとも言えない=4～まったく違う = 1
自律自走する組織自身の中に在るか？	まったくその通り = 7 ～どちらとも言えない=4～まったく違う = 1
自律自走する組織組織の中に在るか？	まったくその通り = 7 ～どちらとも言えない=4～まったく違う = 1
ようこそ失敗自身の中に在るか？	まったくその通り = 7 ～どちらとも言えない=4～まったく違う = 1
ようこそ失敗組織の中に在るか？	まったくその通り = 7 ～どちらとも言えない=4～まったく違う = 1
多様性が育む自身の中に在るか？	まったくその通り = 7 ～どちらとも言えない=4～まったく違う = 1
多様性が育む組織の中に在るか？	まったくその通り = 7 ～どちらとも言えない=4～まったく違う = 1
共通言語で協働促進自身の中に在るか？	まったくその通り = 7 ～どちらとも言えない=4～まったく違う = 1
共通言語で協働促進組織の中に在るか？	まったくその通り = 7 ～どちらとも言えない=4～まったく違う = 1
“サクサク”と“いきいき”自身の中に在るか？	まったくその通り = 7 ～どち

	らとも言えない=4～まったく違う= 1
“サクサク”と“いきいき”組織の中に在るか？	まったくその通り= 7 ～どちらとも言えない=4～まったく違う= 1
知のシェアリングエコノミー自身の中に在るか？	まったくその通り= 7 ～どちらとも言えない=4～まったく違う= 1
知のシェアリングエコノミー組織の中に在るか？	まったくその通り= 7 ～どちらとも言えない=4～まったく違う= 1
自分に問いを立てる自身の中に在るか？	まったくその通り= 7 ～どちらとも言えない=4～まったく違う= 1
自分に問いを立てる組織の中に在るか？	まったくその通り= 7 ～どちらとも言えない=4～まったく違う= 1
いつまでも学びたい力自身の中に在るか？	まったくその通り= 7 ～どちらとも言えない=4～まったく違う= 1
いつまでも学びたい力組織の中に在るか？	まったくその通り= 7 ～どちらとも言えない=4～まったく違う= 1
人の輪、知恵の輪、ビジネスの輪自身の中に在るか？	まったくその通り= 7 ～どちらとも言えない=4～まったく違う= 1
人の輪、知恵の輪、ビジネスの輪組織の中に在るか？	まったくその通り= 7 ～どちらとも言えない=4～まったく違う= 1

B2.4 章 3 節アンケート項目

付表 B2 4 章 3 節アンケート項目

設問	選択肢
あなたはデジタルトランスフォーメーション（以下、DX）を推進する立場である ※1 DX の定義としてデジタイゼーションは含みません（アナログ・物理データのデジタルデータ化、例：FAX の電子化など）。デジタライゼーションまたはデジタルトランスフォーメーションを対象とします。（下図参照） ※2 DX を推進する立場：DX 推進部門スタッフまたはユーザー部門（営業部門・管理部門・製造部門など DX を実行する部門）で DX を担当されている方	YES, NO なお、本項目が NG の場合アンケートが終了

あなたの立場を最も表すものを選択してください。	1 経営陣 2DX 推進部門 3 情報システム部門 4 ユーザー部門（営業部門・管理部門・製造部門など DX を実行する部門） 5 研究開発者 6 その他
あなたが DX を始める段階で、既にプロジェクトは進行していた	まったくその通り = 5 ～どちらとも言えない = 3 ～まったく違う = 1 わからない／答えられない = 0
あなたが推進する立場にある DX はあなたの期待／計画通り進んでいる	まったくその通り = 5 ～どちらとも言えない = 3 ～まったく違う = 1 わからない／答えられない = 0
あなたが普段関わっている DX プロジェクトをイメージしてください。次の各文章はあなたの DX プロジェクトにどの程度あてはまりますか 「社内データやオープンデータを収集し社内プロセス最適化をする」活動はできることから順次実施している	まったくその通り = 5 ～どちらとも言えない = 3 ～まったく違う = 1 わからない／答えられない = 0
あなたが普段関わっている DX プロジェクトをイメージしてください。次の各文章はあなたの DX プロジェクトにどの程度あてはまりますか 積極的にデジタルプラットフォーム（Google cloud platform, Amazon web service, Microsoft Azure, 自社サーバー等）を活用している	まったくその通り = 5 ～どちらとも言えない = 3 ～まったく違う = 1 わからない／答えられない = 0
あなたが普段関わっている DX プロジェクトをイメージしてください。次の各文章はあなたの DX プロジェクトにどの程度あてはまりますか 「社内データやオープンデータを収集し社内プロセス最適化をする」活動は社内全体に向けて活動を広げようとしている	まったくその通り = 5 ～どちらとも言えない = 3 ～まったく違う = 1 わからない／答えられない = 0
あなたが普段関わっている DX プロジェクトをイメージしてください。次の各文章はあなたの DX プロジェクトにどの程度あてはまりますか 協力会社を巻き込み「協力会社データの収集とプロセス最適化」を実施している	まったくその通り = 5 ～どちらとも言えない = 3 ～まったく違う = 1 わからない／答えられない = 0
あなたが普段関わっている DX プロジェクトをイメージしてください。次の各文章はあなたの DX プロジェクトにどの程度あてはまりますか 顧客を巻き込み「顧客データの収集とプロセス最適化」を実施している	まったくその通り = 5 ～どちらとも言えない = 3 ～まったく違う = 1 わからない／答えられない = 0
あなたが普段関わっている DX プロジェクトをイメージしてください。次の各文章はあなたの DX プロジェクトにどの程度あてはまりますか 協力会社データまたは顧客データから付加価値を生み出している	まったくその通り = 5 ～どちらとも言えない = 3 ～まったく違う = 1 わからない／答えられない = 0

あなたが普段関わっている DX プロジェクトをイメージしてください。次の各文章はあなたの DX プロジェクトにどの程度あてはまりますか 社内データ、オープンデータ、協力会社データ、顧客データの「いずれかのデータ」を活用している	まったくその通り = 5 ～どちらとも言えない = 3 ～まったく違う = 1 わからない／答えられない = 0
あなたが普段関わっている DX プロジェクトをイメージしてください。次の各文章はあなたの DX プロジェクトにどの程度あてはまりますか 「いずれかのデータ」を基に新しいビジネスモデルを構築している	まったくその通り = 5 ～どちらとも言えない = 3 ～まったく違う = 1 わからない／答えられない = 0
あなたが普段関わっている DX プロジェクトをイメージしてください。次の各文章はあなたの DX プロジェクトにどの程度あてはまりますか 外部パートナー連携または M&A（企業買収）をして「新しいビジネスモデル」を探索している	まったくその通り = 5 ～どちらとも言えない = 3 ～まったく違う = 1 わからない／答えられない = 0
あなたが普段関わっている DX プロジェクトをイメージしてください。次の各文章はあなたの DX プロジェクトにどの程度あてはまりますか 「新しいビジネスモデル」は会社を代表するビジネスとなっている	まったくその通り = 5 ～どちらとも言えない = 3 ～まったく違う = 1 わからない／答えられない = 0
DX プロジェクトで活用している AI（機械学習）を最も表しているのはどれか	1DX プロジェクトで AI を使っていない 2DX プロジェクトで AI を使っており、人間が中心となり AI は補助的に利用している 3DX プロジェクトで AI を使っており、AI が中心となり、人間は補助的に関わっている 4DX プロジェクトで AI を使っており、AI が自律的に動いており人間は滅多に関わらない
DX プロジェクトで活用している AI（機械学習）が信頼できるかどうかにおいて、どの観点が重要かをお答えください	利便性と信頼性：AI 技術が便利で信頼できるものであること 協力とコミュニケーション：人と協力してコミュニケーションが取れること 社会性と絆：社交性があり絆を形成できること セキュリティとプライバシー保護：セキュリティとプライバシーが守られること 解釈可能性：AI の結果がどう導かれたのかを説明できること
あなたが軋轢を伴う DX を行う際にあなたの身近な人は応援してくれそうですか？ あなたの会社の同僚	まったくその通り = 5 ～どちらとも言えない = 3 ～まったく違う = 1 わからない／答えられない = 0
あなたが軋轢を伴う DX を行う際にあなたの身近な人は応援してくれそうですか？	まったくその通り = 5 ～どちらとも言えない = 3 ～まったく違う = 1 わからない／答えられない = 0

あなたの会社の上司	ない／答えられない＝0
次の各文章はあなた個人にどの程度あてはまりますか#1 DX 推進で他社と取引を行う際、常に会社の利益を優先し損失を避ける行動を取ることができる	まったくその通り＝5～どちらとも言えない＝3～まったく違う＝1　わからない／答えられない＝0
次の各文章はあなた個人にどの程度あてはまりますか#1 私は DX 推進に伴う困難を主体的に解決することができる	まったくその通り＝5～どちらとも言えない＝3～まったく違う＝1　わからない／答えられない＝0
次の各文章はあなた個人にどの程度あてはまりますか#1 常に新しいことにチャレンジするタイプである	まったくその通り＝5～どちらとも言えない＝3～まったく違う＝1　わからない／答えられない＝0
次の各文章はあなた個人にどの程度あてはまりますか#1 リーダーやまとめ役になるのが得意である	まったくその通り＝5～どちらとも言えない＝3～まったく違う＝1　わからない／答えられない＝0
次の各文章はあなた個人にどの程度あてはまりますか#2 専門家のネットワークを作るのが得意である	まったくその通り＝5～どちらとも言えない＝3～まったく違う＝1　わからない／答えられない＝0
次の各文章はあなた個人にどの程度あてはまりますか#2 新しいアイデアをビジネスや業務改善に活かすのが得意である	まったくその通り＝5～どちらとも言えない＝3～まったく違う＝1　わからない／答えられない＝0
次の各文章はあなた個人にどの程度あてはまりますか#2 DX を推進するためなら積極的に努力する	まったくその通り＝5～どちらとも言えない＝3～まったく違う＝1　わからない／答えられない＝0
次の各文章はあなた個人にどの程度あてはまりますか#2 私はかなり主体的に DX 推進に取り組んでいる	まったくその通り＝5～どちらとも言えない＝3～まったく違う＝1　わからない／答えられない＝0

C1.5 章コードシステム

5章のインタビュー結果をまとめた際のコードシステムは以下の通りである。本分析で特に用いたのはFinal exploitation pattern, Exploitation pattern, Human machine collaborationである。

付表 C1 5章コードシステム

コードシステム	
コードシステム	
	Actor
	Management
	Actor_Development

	Actor_IT Dept.
	Actor_Plannner (DX)
	Actor_User
	Exploitation pattern
	4. Autonomy
	3. ML-centered Human assistance
	2. Human-centered ML assistance
	1. Visualization
	Human machine collaboration
	5. Less trust in the MLS
	4. Trust in the MLS
	3. Interpretation of MLS by humans
	2. Effort to involve users
	1. Fit to users sense

C2.5 章インタビューデータとコード

5章のインタビュー結果をテーマティック・アナリシス法により切片化とコーディングを行った結果を以下に示す。切片番号はインタビュー対象者一番号の割り付けにより一意にナンバリングを行っている。

付表 C2 5章インタビューデータとコード

切片番号	インタビューデータ	コード
5-1	ビッグデータ分析をするためのシステムがなかったため、大規模データに対する機械学習処理を行うのは容易ではなかった。GCP に集約した後、BigQuery でデータを処理し、その後 Python で AI モデルの開発を行った。	可視化ーデータ結合プロセス
4-1	オンラインデータとオフラインデータを組み合わせるのは困難である。集約、可視化、要約、再び可視化を繰り返し、データ利用を想像しながらプロセスをすすめた。このプロセスを自動化することは役立つが、現実にはマーケティングに精通したデータサイエンティストが必要だ。	可視化ーデータ結合プロセス
4-2	MLS を使いながらデータの可視化を試みている。	可視化ー仮説検証プロセス
5-2	(ユーザーである) マーケティング担当者もデータサイエンティストもアウトプット定義がイメージできない中、アウトプットを評価しながら開発を進めた。ユーザーとの理解を深め合意に至るには1か月かかり、毎日可視化に基づいて議論を行った。	可視化ー仮説検証プロセス

7-1	要求が具体的でないとき、データを（BI システムに）投入して視覚化された画面でさまざまなことができると感じた。	可視化—ユーザーとの共創
13-1	分類の際に視覚化を使用した。	可視化—ユーザーとの共創
2-1	機械の判断が正しいことを証明するために視覚化を行った。	可視化—ユーザーとの共創
6-1	顧客から使えるものとは言われていたが、具体的な数字は示されていなかった。ユーザーは精度を参考にしか見ていない。顧客は使ってみて感覚的な間違いの数で評価する。	人間中心 ML 補助—過度に高い AI への期待値
6-2	AI の理解があまりなかったため、期待値が過剰であった。	人間中心 ML 補助—過度に高い AI への期待値
10-1	精度に対する厳しい要求があったが、すり合わせ過程でバー（基準）は下がった。AI は誤りをしてはならないと主張する者が多い。	人間中心 ML 補助—過度に高い AI への期待値
13-2	ユーザーは AI に大きな関心を示している。しかし、使い始めたばかりであり、利用率を把握する段階である。	人間中心 ML 補助—AI の活用困難性
2-2	ブロッカーになる人は営業所ではいたが、企画の人が説得してくれたのであまり感じなかった。反対する理由は、自分たちは他とは違う、お客さんの影響が強いなど自分たちは特別であるという主張が多かった。これは統制されたくないという気持ちの表れかと思われる。	人間中心 ML 補助—AI の活用困難性
3-1	AI が 10%間違ってもユーザーは反発する。これは将来的な課題である。	人間中心 ML 補助—AI の活用困難性
3-2	（日報の分類における）仕様を確定する際の課題は、分類の評価方法である。それが正しいかどうか（ユーザー部門に確認をしながら）、そしてどのように精度を向上させるかについて悩むことが多かった。	人間中心 ML 補助—積極的な人間の介入
2-3	人間の仕事を支援するシステムであるため、システムの出力値の解釈は人間によって行われる。	人間中心 ML 補助—積極的な人間の介入
11-1	ユーザーとしては、顧客に理解させるのが難しかった。	人間中心 ML 補助—積極的な人間の介入
9-1	データ取得自体に問題はない。なぜなら、データはよく構造化されたデータウェアハウスにあるからだ。説明変数を増やすために、ノイズ削減とクレンジングが必要だった。データの断片化は起こっていない。ビジネスプロセスはデータに基づいて運営されている。開発テストでは、パイプラインジャングルがある。データを蓄積するプロセスでジャングルになる。	ML 中心人間補助—パイプラインジャングルとデータエンジニアリングの難しさ

12-1	ETL 後に Airflow によるフロー処理を行った。ここに運用上の問題がある。IN 側が変わるという問題もあり、パイプラインが的確に動くわけでもない。想定しないエラー、データの整合性がとれなくなる。論理的な部分があれば、動かしたらパンク（データ量が多くてパンク）することもある。エンジニアリング的な苦労は多い。	ML 中心人間補助 ーパイプライン ジャングルとデータエンジニアリングの難しさ
9-2	物流（計画を機械学習により最適化すること）に関しては現場が反対することがない。なぜならばデータを基にして物流が動いているためである。計画系で人系オペレーションが存在しない。人ではやりきれないスケールの仕事である。人がやっていた業務を切り替えると問題が起きるであろう。機械でやってほしいという意志が強い	ML 中心人間補助 ーシステムの成熟
1-1	機械主導でプロジェクトマネジメントは未来の話になる。最適化をするためには調整的な業務が発生する。人と人とのインタラクションが入る。そこを機械が代替するためには、パーソナライズ、説明可能性が必要になってくる	ML 中心人間補助 ーシステムの成熟
2-4	運用時、稼働直後変な値が出ることがあったので都度バグ対応した。現場の感覚で指摘が入る。顧客の期待値が高い。ここがこなれてくると、システム側が正しいという状態になる。1、2 年くらいかかった。現場になじむまでにはこれくらい時間かかる。信用を得るためにはそれなりに時間がかかる。	ML 中心人間補助 ーシステムの成熟
2-5	顧客は動いてくれればよい。ロバスト性を意識した。エラーを起こしても、業務が回ることを意識。ロバスト性確保の上での課題は欠損値・異常値対策、データが少なくても回るようにすること。（ビジネス自体は停止を許されないため、システムの堅牢性を意識し欠損値・異常値、データが少なくても結果を返すこととした。正確性を犠牲にしても堅牢性を確保した。）	ML 中心人間補助 ーシステムの成熟
2-6	機械の判断が正しいことを証明するためにデータを可視化した。それにより、現場からの支持を得ることにつながる。	ML 中心人間補助 ーユーザーとの信頼
8-1	出力をどう解釈するか、そこを納得させるためにロジックの開示とアカデミック活用をしている。	ML 中心人間補助 ーユーザーとの信頼
12-2	情報推薦（レコメンドロジック）には偏った推薦が起これる。公平性は問題ではないが、将来的な考慮事項である。	ML 中心人間補助 ーユーザーとの信頼
10-2	逐次学習も機能としてはあるが、AUTO にするのは大変。	自律ー異常系処理の難しさ
11-2	システム出力値が異常値である場合、人間が問題を解決しています。これを自動的に解決したいのですが、方法が見えてきません。	自律ー異常系処理の難しさ
12-3	大量のデータはパイプラインを詰まらせます。パイプラインが複雑であるため、これを簡素化することが重要です。しかし、仕様がないため難しいです。	自律ー異常系処理の難しさ

9-3	物流（計画を機械学習により最適化すること）に関しては現場が反対することがない。—中略—人ではやりきれないスケールの仕事である。	自律データ駆動型オペレーション
11-3	広告を見た正確な訪問者数は誰にもわかりません。そのため、理論値のみを説明します。	自律データ駆動型オペレーション
13-3	社長のトップダウンが入ると、ユーザーは積極的に動きまゝす。経営陣が推進するきっかけは、会社内にミスや苦情がある場合や、同業他社が同じことをしている場合です。	経営陣
1-2	マネジメントに寄りすぎると、現場から支持を得られない。	経営陣
15-1	上長からはいつまでこのプロジェクトをやっているのという話はあった。（担当部門長が）ブロックしていた。上長は技術がわかるわけではなく、プロジェクトのうたい文句もしっかりあったので権限を渡してもらっていた。	経営陣
5-3	データ解析プロジェクトでシステム担当がハードルになりえることは多かった。セキュリティ面。データの利用範囲、プライバシーポリシー順守。	情報システム部
14-3	ブレーキを踏むのは情報システム部門。管理しているシステムの枠外のことをやらないでほしい。セキュリティリスクについて主張がある。私たちは説得とすり合わせを繰り返しました。	情報システム部
1-4	プロジェクト異常の点数を公開すると反発があったりする。公平性も気にする。モデルが 100%正しいわけではない。—中略—不公平な結果は出ることがあるが、その意味合い、結果の解釈が必要となる。	機械学習応用システムへの信頼
14-4	機械学習応用システムによる回答は 60-70%正確ですが、現場はそれを受け入れます。システムからの情報をどのように絞り込むかは人間の仕事です。つまり、AI と人間は協力して働いています。	機械学習応用システムへの信頼
2-11	公平性の面で、機械学習応用システムの出力は人事評価に使用されます。—中略—配送をちゃんとやるのがスタッフの仕事、付加価値となる。巡回タイミングは今回のシステムである程度公平化できた。	機械学習応用システムへの信頼
9-6	公平性の面で、機械学習応用システムの出力は人事評価に使用されます。—中略—配送をちゃんとやるのがスタッフの仕事、付加価値となる。巡回タイミングは今回のシステムである程度公平化できた。」（インタビュー対象者 2-11） 「物流（計画を機械学習により最適化すること）に関しては現場が反対することがない。なぜならばデータを基にして物流が動いているためである。計画系で人系オペレーションが存在しない。人ではやりきれないスケールの仕事である。	機械学習応用システムへの信頼
9-7	最初商品を取り入れるときは感覚で（人間が最初の在庫計画を作成）やっている。データがたまるとデータ駆動にしている。	機械学習応用システムへの信頼

15-1	AI が出力することによって、公平性が上がる。そのためのトラブルが減る。検査員の習熟度によるデータのばらつきのリスク回避ができる。	機械学習応用システムへの信頼
9-8	(機械学習応用システムは) 出てきた結果がブラックボックスになるので、プロセス議論ができない。結果が良くないとダメだねとなってしまう。	機械学習応用システムへの不信
11-7	(機械学習応用システムは) 出てきた結果がブラックボックスになるので、プロセス議論ができない。結果が良くないとダメだねとなってしまう。	機械学習応用システムへの不信
14-6	AI がどういいか作っている人しかわからないし、作っている人でも 100%理解しているわけではない。	機械学習応用システムへの不信
9-9	倫理上の問題が出るのは、お客さんにリコmendをする際。気持ち悪さがおきる。	機械学習応用システムへの不信
13-8	(リスク対応は) 最後は人。最後 (対象システムの最終目標) のフェーズはA I が自動でメールを出す。お客様の取引サイドに通知を出す。これがあるとリスクがあるが。	機械学習応用システムへの不信

謝辞

本論文の執筆にあたり、多くの方々からご指導とご支援を賜りました。ここに深く感謝の意を表します。まず初めに、この研究を遂行するにあたり、多大なるご協力をいただいたすべての方々に、心より御礼申し上げます。

指導教員である北陸先端科学技術大学院大学の内平直志教授には、長きにわたり親身なご指導と温かいご支援をいただきました。研究の方向性から論文執筆に至るまで、的確なアドバイスと励ましを賜り、心より御礼申し上げます。特に研究が行き詰まった際には、深い洞察に基づくご助言をいただき、新たな視点と方向性を示してくださいました。内平先生の専門的な知見と豊富なご経験がなければ、本研究を完遂することはできませんでした。改めて深く感謝申し上げます。

学位論文審査の審査委員をお引き受けいただきました北陸先端科学技術大学院大学の敷田麻実教授、白肌邦生教授、DAM Hieu Chi 教授、そして QAML 株式会社の吉岡信和先生には、貴重なご意見とご指摘を頂戴いたしました。お忙しい中、丁寧に論文をお読みいただき、鋭いご指摘と建設的なご意見を賜りましたこと、心より感謝いたします。先生方のご助言により、本研究の内容を一層充実させることができました。

副テーマのご指導をいただいた元早稲田大学商学大学院教授の大江建先生、そして北陸先端科学技術大学院大学の神田陽治教授には、副テーマにおける「中小ものづくり企業の生き残り戦略」という新規事業論の論文を執筆するにあたって、多大なるご支援を賜りました。お二人の専門的な見解や豊富な知識により、研究の幅を広げ、深みを持たせることができました。貴重なお時間を割いてご指導いただき、心より感謝申し上げます。

本研究において、インタビューにご協力いただいた企業の皆様には、貴重なお時間を割いていただき、心から御礼申し上げます。皆様の実務的なご経験と洞察をお聞きすることで、理論と実践を結びつける貴重な機会を得ることができました。具体的な事例や現場でのご意見は、研究の視野を広げ、新たな発見につなげる上で大変有益でした。誠にありがとうございました。

第 5 章の執筆に際し、ワーキンググループにご参加いただき、論文の共著をいただいた石谷規彦先生、森俊樹先生、根本学先生、西村一彦先生にも深く感謝の意を表します。皆様のご協力がなければ、本章の完成は成し得ませんでした。

機械学習工学の論文（Software Engineering Design Patterns for Machine Learning Applications）を共著をさせていただいた鷺崎弘宜先生、Foutse Khomh 先生、Yann-Gaël Guéhéneuc 先生、名取直毅先生、竹内広宜先生、本田澄先生、土肥拓生先生に心より感謝申し上げます。皆様のご指導とご助言により、本研究を進めることができました。

内平研究室の皆さんには、日々のディスカッションや温かい励ましをいただきました。研究室での活発な議論や情報交換は、研究を進める上で大きな支えとなりました。皆さん

との交流を通じて、多くの刺激を受け、新たな視点やアイデアを得ることができました。
研究生生活をともに過ごした仲間たちに、深く感謝いたします。

早稲田大学の理工学術院の朝日透教授、河合隆史教授、そして商学学術院の坂野友昭教授には、博士課程の活動において多大なご支援とご助言をいただき、誠にありがとうございました。皆様の励ましとご指導に深く感謝申し上げます。

最後に、私の研究活動を理解し、支えてくれた家族に心から感謝いたします。

研究業績リスト

A. 学術誌掲載論文

A-1. (査読有)

Satoshi Okuda and Naoshi Uchihira, 2024, “Exploitation process for machine learning systems”, International Journal of Innovation and Technology Management.

A-2. (査読有)

奥田聡・更田誠・大江建, 2021, 「中小ものづくり企業の生き残り戦略」『Venture Review』, 37:pp. 41-55.

B. 国際学会口頭発表論文

B-1. (査読有)

Okuda, S., Nemoto, G., Mori, T., Ishitani, N., Nishimura, K., and Uchihira, N., “Exploitation pattern for machine learning systems”, The 36th International Technical Conference on Circuits/Systems, Computers and Communications (ITC-CSCC21), pp1-4, 2021.

B-2. (査読有)

Okuda, S., Uchihira, N. 2023. “Digital Transformation Classification Types and Evolution Process for Established Companies”. In: Christine Leitner, Jens Neuhüttler, Clara Bassano and Debra Satterfield (eds) The Human Side of Service Engineering. AHFE (2023) International Conference. AHFE Open Access, vol 108. AHFE International, USA. <http://doi.org/10.54941/ahfe1003124>

C. 国内学会口頭発表論文

C-1. (査読無)

奥田 聡・石谷規彦・森 俊樹・根本 学・西村一彦・内平直志, 『機械学習応用システムの深化パターンと課題体系』, 信学技報, vol. 120, no. 170, KBSE2020-4, pp. 19-24, 2020.

C-2. (査読無)

奥田 聡・石谷規彦・森 俊樹・根本 学・西村一彦・内平直志, 『機械学習応用システムの深化パターンと開発手法』, Proc. Of the 日本ソフトウェア科学会機械学習工学研究会, 2020.

C-3. (査読無)

奥田 聡・石谷規彦・森 俊樹・根本 学・西村一彦・内平直志, “機械学習応用システムの深化パターンと開発手法”, 日本MOT学会年次研究発表会, 2020.

D. 国際学会口頭発表論文

D-1. (査読無)

Satoshi Okuda, Makoto Sarata, Takeru Ohe, “Survival Strategies for Small and Medium-Sized Manufacturing Companies –Effectuation and its place in Survival Strategies used by Japanese SME –”, THE GLOBAL RESEARCH CONFERENCE ON MARKETING AND ENTREPRENEURSHIP, 2021.

E. 共同研究・競争的資金等の研究課題

経済産業省 共同講座創造支援事業により以下の2つを研究として実施。

E-1. データ駆動型経営を実現するためのDX人材育成プログラムの実証研究

E-2. 事業変革型DX人材育成実践講座 ～企業内DXを推進するフレームワークとその活用～

これらは、AHFEでの “Digital Transformation Classification Types and Evolution Process for Established Companies” に記述されているDX分類に従って開発した研修プログラムである。博士論文4章2節の研究は本プログラム内で収集したデータを元に分析を実施した。