

論文 / 著書情報
Article / Book Information

題目(和文)	エージェント技術によるゲーミングのシナリオ分析に関する研究—ゲームログを利用したファシリテーションを目指して—
Title(English)	
著者(和文)	坂田 顕庸
Author(English)	Akinobu Sakata
出典(和文)	学位:博士(工学), 学位授与機関:東京工業大学, 報告番号:甲第12681号, 授与年月日:2024年3月26日, 学位の種別:課程博士, 審査員:山村 雅幸,石井 秀明,小野 功,日高 一義,中丸 麻由子
Citation(English)	Degree:Doctor (Engineering), Conferring organization: Tokyo Institute of Technology, Report number:甲第12681号, Conferred date:2024/3/26, Degree Type:Course doctor, Examiner:,,,,
学位種別(和文)	博士論文
Type(English)	Doctoral Thesis

2023 年度 博士論文

エージェント技術による

ゲーミングのシナリオ分析に関する研究

—ゲームログを利用したファシリテーションを目指して—

坂田 顕庸

東京工業大学大学院

総合理工学研究科

知能システム科学専攻

指導教員： 山村 雅幸

概要

本論文では、ゲーミングのデブリーフィングにおいて実施される What-If 分析を実行するファシリテータ同士の間で、ゲームで起こり得るシナリオとシナリオの生成要因となり得るプレイヤーの行動に関して認識を共有することに資する知識である P-GL-AA (Patterns of Gaming Logs and Actions of Agents) を、エージェントがプレイしたログから抽出できることを示す。

第1章「序論」では、本論文のアウトラインを示す。従来、ゲーミングにおける最も重要なフェーズであるデブリーフィングでは、ファシリテータによってゲームの過程で起こり得る仮説的なシナリオが検討される。シナリオとは、互いに類似した特徴を備えたゲームのログの集合のことである。しかしながら、ファシリテータによるファシリテーションには個人差があるため、ファシリテータ同士の間でシナリオの検討結果に齟齬が生じる可能性がある。そこで、本研究では P-GL-AA をエージェントのログから抽出する手法を提案する。P-GL-AA とは、ゲームのログの類型と類型を生じさせる要因となり得るエージェントの行動を指す。もしも、ファシリテータがゲーミングを実施する前に P-GL-AA を把握することができれば、ゲームで起こりうるシナリオやシナリオの生成に関わるプレイヤーの行動に関する認識を、ファシリテータ同士の間で共有した上で、ファシリテータはデブリーフィングでファシリテーションをすることができる。ファシリテータがゲーミングを実施する前に P-GL-AA を得ることは困難である。なぜなら、P-GL-AA はゲームの解説書には載せられておらず、また、対象のゲームを用いたゲーミングの経験に乏しいファシリテータがゲーミングを実施して少数のログを収集して分析した結果には妥当性に乏しく、さらに被験者実験を伴うゲーミングを繰り返して大量のログを収集するにも時間がかかるという理由があるためである。

第2章「関連研究」では、ゲーミングのデブリーフィングでの What-If 分析の支援を志向した研究を紹介し、ログから P-GL-AA を推定する手法上の課題点をそれぞれの研究に対して挙げ、本研究の提案手法との差分を明示する。従来のデブリーフィングにおけるファシリテーションには個人差があることから、ファシリテータ次第で What-If 分析の内容が異なると考えられる。これに対して、近年、エージェントにゲームをプレイさせて得たログを元に What-If 分析を実施するというアプローチが新たに提唱され

た。しかしながら、いずれのアプローチにおいても、ファシリテータ同士の間でゲームで起こりうるシナリオやシナリオの生成要因となり得るプレイヤーの行動に関する認識は共有されない。

第3章「提案手法」では、本研究の提案手法であるログ分析手法と分析対象のゲームの仕様を説明する。ファシリテータがP-GL-AAを把握するにあたって、被験者実験を前提としたゲーミングで地道にログを収集して求めることは、時間がかかるために困難である。加えて、もし仮に十分なログが存在したとしても、提案手法がなければ、ファシリテータが各人でログを分析してゲームのプロセスを吟味するしかなく、手間と時間がかかるだけでなく、分析結果がファシリテータ同士の間で一致しない可能性がある。これに対して、提案手法は、対象のゲームのゲーミングを実施する最初のファシリテータが自らエージェントを設計し、エージェントにゲームをプレイさせてログを収集し、収集したログを類型化し、ログの類型同士を比較して類型化の要因となり得るエージェントの行動を推定するというプロセスを経て、ファシリテータはP-GL-AAを得ることができる。本研究の提案手法を適用可能なゲームは「目的を達成するためにルールや資源という制約の下で行動する1人のプレイヤーによる競争または遊びであり、シミュレーションとしての側面を持つ」という要件を満たす必要がある。さらに、このゲームのエージェントは資源配分問題を解くことを要求される。ゲームは N^2 ダイアグラムによって表現可能なシステムとして表現されるものに限る。 N^2 ダイアグラムはシステムエンジニアリングにおいてシステムのコンポーネント間相互の入出力のネットワーク関係を整理するために用いられる。

第4章「DEAを用いたゲーミングからの知識抽出手法」では、提案手法を用いて、ゲームプレイのログからログの類型を抽出できることを示す。データ包絡分析法(DEA, Data Envelopment Analysis)で、エージェントにゲームをプレイさせて得たログを、資源配分の方針の違いに基づいて類型化する。その結果、ログの類型を抽出できることを確かめる。デブリーフィングでは仮説的なシナリオの検討が重要である。従って、提案手法を使用することで、ファシリテータはゲームで起こり得るシナリオの存在を把握することができる。これに加えて、ファシリテータ同士でゲームで起こり得るシナリオについて認識を共有することができるようになる。これにより、どのファシリテータのデブリーフィングでも、シナリオに関する共通の認識の下でWhat-If分析を実行できるようになる。

第5章「DEAを用いたゲーミングからの知識抽出手法」では、提案手法を用いて、ゲームのログからログの類型化の要因となり得るエージェントの行動を推定できるこ

とを示す．ここでは，まず，ログを階層化クラスタリングとレーベンシュタイン距離を用いて，距離の近さに基づいてログを類型化し，続いて，決定木を用いてログのタイプの生成要因となり得るエージェントの行動を分析する．その結果，提案手法でログのタイプの生成要因となり得るエージェントの行動を推定できることを示す．デブリーフィングでは仮説的なシナリオの検討が重要である．提案手法により，ファシリテータはゲームで起こり得るシナリオを生成し得るエージェントの行動を知ることができる．これに加えて，ファシリテータ同士でゲームで起こり得るシナリオを生成し得るエージェントの行動について認識を共有することができるようになる．これにより，どのファシリテータのデブリーフィングでも，シナリオを生成し得るエージェントの行動に関する共通の認識の下で What-If 分析を実行できるようになる．

第6章「結論」では，第4章と第5章の成果を整理し，エージェントにゲームをプレイさせて得たログから，ログのタイプとログの類型化の要因となり得るエージェントの行動を特定して，P-GL-AA を推定する手法を提案するという本研究の目的が達成できたかどうかを議論する．本研究の課題として，提案手法のスケール性の問題と，今後の本研究の発展について考察する．

Abstract

This thesis “Research on Scenario Analysis in Gaming Using Agent Technology: Toward Game-Log-based Facilitation” proposes that P-GL-AA (Patterns of Gaming Logs and Actions of Agents) be able to be extracted from game logs played by agents. P-GL-AA denotes typologies of game logs (scenarios) and the actions of agents contributing to this typification, which be able to be useful knowledge in making What-If analysis in gaming debriefing less reliant on facilitators’ facilitation abilities.

Chapter 1 introduces this study’s purpose and problems.: the research proposes the method for the extraction of P-GL-AA aiming to make What-If analysis less dependent on facilitators’ facilitation skills. In order to achieve the purpose, first, it needs to testify to be able to categorize game logs into multiple log sets and to extract actions causing the classification of game logs.

Chapter 2 surveys related research and compares the proposed approach with a conventional and typical facilitation one and an agent-based log analysis one. These approaches fail to identify potential scenarios or agent actions crucial for achieving facilitator-independent What-If analysis, however, the proposed has the possibility to overcome their limitation. Chapter 3 explains the details of the proposed methodology. This study proposes to make agents play the game, classify the game logs, and identify agent actions causing classification, thereby obtaining P-GL-AA.

Chapter 4 illustrates it is able to categorize logs into multiple sets, which have similar-featured logs respectively, from game logs. These sets were called scenarios. As a result of this experiment, data envelopment analysis (DEA) succeeded in extracting several scenarios from the game logs. In addition, it was shown that the logs comprising each scenario were able to be compared with each other under the common policy of resource allocation.

Chapter 5 depicts it is able to identify the actions contributing to identifying scenarios from logs. In this experiment, the game logs were first classified into several scenarios according to their similarity with hierarchical clustering, and then C4.5 identified the factors contributing to dividing the logs into these scenarios. This means

P-GL-AA was able to be extracted. Chapter 6 concludes by affirming the achievement of the dissertation's goal: extracting log typologies and agent actions from logs generated by agents playing games, thus deriving P-GL-AA.

目次

概要	i
第1章 序論	1
1.1 はじめに	1
1.2 研究の背景	1
1.3 研究目的	3
1.4 本研究の構成	4
第2章 関連研究	5
2.1 はじめに	5
2.2ゲーミング	5
2.2.1 ゲーミングの定義	5
2.2.2 ゲーミングの特徴	6
2.2.3 ゲーミングの実行手順	8
2.3 本研究のアプローチの独自性	9
2.4 まとめ	10
第3章 提案手法	13
3.1 はじめに	13
3.2 提案手法	13
3.2.1 提案手法の説明	13
3.2.2 提案手法の使用が想定されるユーザー	14
3.2.3 提案手法がファシリテーションに与え得る影響	14
3.3 本研究で使用するゲーム	14
3.3.1 ゲームの基本要件と定義	15
3.3.2 ゲームの目的	16
3.3.3 シミュレーションモデル	16

3.3.4	ゲームおよびエージェントのモデル	19
3.4	まとめ	28
第4章	DEAを用いたゲーミングからの知識抽出手法	29
4.1	はじめに	29
4.2	実験計画	29
4.2.1	ゲームおよびエージェントのモデル	29
4.2.2	計算機環境	29
4.2.3	実験手順	30
4.2.4	ログの分類方法	30
4.2.5	実験結果	34
4.2.6	提案手法と DEA を使用した理由	37
4.2.7	考察	38
4.3	まとめ	42
第5章	ログクラスタ分析を用いたゲーミングからのシナリオ分岐要因の抽出手法	43
5.1	はじめに	43
5.2	実験計画	43
5.2.1	ゲームおよびエージェントのモデル	43
5.2.2	計算機環境	44
5.2.3	実験手順	44
5.2.4	分析方法	45
5.2.5	結果	48
5.2.6	考察	52
5.3	まとめ	53
第6章	結論	55
6.1	本研究の結論	55
6.2	本研究の貢献	56
6.3	今後の展望	59
	謝辞	63
	参考文献	63

第1章 序論

1.1 はじめに

本章では、研究の背景、目的、課題、および論文の構成を述べる。本研究の目的は「ファシリテータがゲーミングシミュレーション（以下、ゲーミング）を実施する前の段階でエージェントにゲームをプレイさせて得たログからの P-GL-AA（Patterns of Gaming Logs and Actions of Agents）の抽出手法」であることを説明する。P-GL-AA とは、「ゲームプレイのログの種類と、その類型化の要因となり得るエージェントの行動」を指す。さらに、この目的の達成のため、エージェントによるゲームプレイのログからログの種類が抽出可能かを確かめ、さらに、ログの類型化の要因となり得るエージェントの行動を推定可能かを確かめる。

1.2 研究の背景

高等教育では、学生が現実社会の複雑なシステムの構造の理解を深めるための教育機会を提供する。高等教育の現場ではゲーミングを用いた教育に注目が集まっている [1]。ゲーミングは体験（実験）とルールに基づいたインタラクティブな環境を指す [2]。そこでは、プレイヤーはゲーミングにおいて自らが取った行動とゲームの内部やその周辺に組み込まれたフィードバック機構を通して経験する行動の影響を体験して学習する [2]。さらに、プレイヤーはゲームでの体験を通して学んだ事柄と現実社会の現象を比較・検討するよう要求され、その結果、現象の理解を深めることができる [3]。

ゲーミングはブリーフィング、ゲームプレイ、デブリーフィングという三つの要素から構成されるが [4][5]、それらの中で、特にデブリーフィングがゲーミングの学習効果を高める上で重要であると考えられている [6]。デブリーフィングはゲームの演習後に行われるプレイヤーの相互作用による振り返りと討論の段階を指す [5]。デブリーフィングにおいて、プレイヤーはゲームの演習での体験を振り返り、他のプレイヤーとの討論

を通して互いの情報や知識を共有し、学びや気づきを経験することで、当該ゲームのモデルやその大本である社会システムや現象への理解を深めることができる [3]。デブリーフィングはファシリテータによるファシリテーションによって進行する [7]。

デブリーフィングではゲームのプロセスの経路依存性の評価が重要である [8]。ゲームのプロセスの経路依存性とは、ゲームの過程でプレイヤーによって下された決定や出来事がゲームの結果に影響を与えることを指す。デブリーフィングでは、ゲームにおける決定的な判断や起こり得るシナリオを見つけて、ゲームのプロセスの経路依存性を評価する必要がある。Kriz もまた、仮説的なシナリオについての検討がデブリーフィングで重要であると述べている [9]。

ファシリテータは仮説的なシナリオの検討に What-If 分析を用いる。What-If 分析とは、特定のシミュレーションモデルを参照して、独立変数の変化が従属変数に与える影響を明らかにするために用いられる [10]。What-If 分析は、ゲーミング [11][12] や計算機シミュレーション [13] の結果の検討で利用されている。

しかしながら、ファシリテータによる What-If 分析の内容やその効果は常に同じであるとは言い難い。なぜなら、ファシリテーションには個人差があるためである。Kato は、ファシリテータは、ファシリテーションについて独自の理論を持っており、自らの理論に則ってゲーミングの状況を管理していると述べている [14]。Crookall は、ファシリテータのファシリテーションの方法論は学習に関する哲学や社会的かつ直感的な期待などに依存すると述べている [15]。中村も、ファシリテーションは職人芸的な側面があると述べている [7]。ファシリテータ同士の間、ファシリテーションに対する考え方、方法論、スキルや経験に違いがあるということは、ファシリテーションの内容や結果がそれらの要素に左右される可能性があることを意味する。このことは、ファシリテータとしてゲーミングの教育効果はファシリテータが持つコンピテンシー次第であるという Hauge らの研究結果 [16] によっても支持される。

以上を踏まえ、本研究では、デブリーフィングでファシリテータが What-If 分析を実施する上で役に立つと考えられる P-GL-AA (Patterns of Gaming Logs and Actions of Agents) に着目する。P-GL-AA とは「ゲームプレイのログの種類と、その類型化の要因となり得るエージェントの行動」と定義する。上述の通り、デブリーフィングではファシリテータによって What-If 分析が行われ、そこではゲームプレイの過程で起こり得る様々なプロセスが吟味される。ところが、ファシリテーションには個人差があることから、ファシリテータ同士の間で What-If 分析で検討の対象となるゲームのプロセスやプレイヤーの判断の評価が異なる可能性がある。これに対し、仮にファシリ

テータがゲーミングを実施する前に P-GL-AA を獲得できれば、ファシリテータ同士の間で What-If 分析で検討の対象となるゲームのプロセスやプレイヤーの判断の評価に関する認識を共有することができ、その上でファシリテータはデブリーフィングでファシリテーションをすることができる。

しかしながら、ファシリテータがゲーミングを実施する前に P-GL-AA を獲得することは困難である。その理由は三点ある。第一に、ファシリテータはゲーミングで 사용되는ゲームの仕様書を入手して内容を把握することが難しい。仕様書には、ゲームの設計者がどうゲームを様々な角度から分析した結果が載っているが、ファシリテータはゲームの一ユーザーに過ぎないため、ゲームの仕様書にアクセスすることが難しい。ゲーミング研究で利用実績の多いビジネスゲームであるアレクサンダーアイランドやベーカリーゲーム [17][18] のマニュアルに掲載されている情報もゲーム自体のルールやシミュレーションのモデルが主であり、ゲームの結果の詳細な分析結果は掲載されていない。第二に、少数のログを集めてファシリテータがログを分析しても、当該ファシリテータに分析対象のゲームを扱った経験が乏しい場合は、分析結果の正しさに疑念が残る。第三に、被験者実験が前提であることが多いゲーミングでは、多数のログを収集するのに長い時間がかかる [19]。

1.3 研究目的

そこで本研究では、ファシリテータがゲーミングを実施する前の段階で P-GL-AA (Patterns of Gaming Logs and Actions of Agents) を得る手法を提案する。提案手法の有用性を例証するため、以下に示す 2 つの知識を獲得できることを実験によって示す (図 1.1)。

実験 1

エージェントによるゲームプレイのログからログの類型が抽出可能かを確かめる。

実験 2

エージェントによるゲームプレイのログからログの類型化の要因となり得る行動が推定可能かを確かめる。

本研究の目的:ファシリテーターがゲーミングを実施する前の段階でP-GL-AAを獲得する手法を提案する.



No.	問題	問題解決方法(実証実験)
1	エージェントによるゲームプレイのログからログの類型が抽出可能かを確かめる.	エージェントによる資源の配分と獲得の結果の類似性に基づいてログを類型化する(第四章).
2	エージェントによるゲームプレイのログからログの類型化の要因となり得る行動を推定可能かを確かめる.	エージェントによる資源配分の意思決定の過程の類似性に基づいてログを類型化し、いつ・どの意思決定がログの類型化に影響を与えたかを明らかにする(第五章).

図 1.1: 研究の目的と課題

1.4 本研究の構成

本論文は以下のように構成される. まず, 第2章「関連研究」では, まずゲーミングについて詳細に説明し, 次に本研究の独自性を示すために What-If 分析の支援に関わる研究を比較する. 第3章「提案手法」では提案するログの分析手法, 本研究が対象とするゲームの定義を行う. 第4章「DEA を用いたゲーミングからの知識抽出手法」では, エージェントによるゲームプレイのログからログの類型が抽出可能かを確かめる. ここでは, シンライフキャリアゲーム バージョン2という既存のゲームを用い, そのログを分類してシナリオを抽出する. 第5章「ログクラスター分析を用いたゲーミングからのシナリオ分岐要因の抽出手法」では, エージェントによるゲームプレイのログからログの類型化の要因となり得る行動が推定可能かを確かめる. 第4章と同じゲームを用いてログを収集し, 類型化してシナリオを抽出し, さらにシナリオ同士を比較して類型化を生じさせたエージェントの行動を明らかにする. 第6章「結論」では, 博士論文をまとめ, 最後に本研究の学術的な貢献および今後の課題について述べる.

第2章 関連研究

2.1 はじめに

本章では、まずゲーミングについて説明する。次に、ファシリテータによる What-If 分析の支援を目的とした研究を比較して本研究の新規性について議論する。

2.2 ゲーミング

本節では、ゲーミングについて説明するにあたり、まず、本研究におけるゲーミングの定義づけを行う。続けて、ゲーミングの特徴について説明する。最後に、ゲーミングを構成する要素について解説する。

2.2.1 ゲーミングの定義

ゲーミングは、歴史が古く、現代においても非常に多くの研究者が参画する活気ある研究分野である。しかしながら、ゲーミングとは何かについて研究者間の間でも共通の理解がされているわけではない [3]。そのため、その概念を理解することは難しい。以下では、これまでの研究におけるゲーミングの定義を紹介し、最後に本研究におけるゲーミングを定義づける。

一般に、ゲーミングは、人間がゲーム形式のシミュレーション環境にアクターとして能動的に参加し、各人の意思決定に基づいて進行する仮想的な社会的な営みと説明される。例えば、加藤は、ゲーミングとは、ゲーム活動という「能動的な参加 (participation)」と、シミュレーションという「実験的な探査 (exploration)」とが融合した、調査・研究機会を我々に提供するものであると述べている [20]。新井も、ゲーミングとは、ゲーム的側面を持ったシミュレーションの活動であると述べている [3]。加えて、Greenblat も、「ゲーミングとは、ゲーム的側面を持つシミュレーション、すなわち、シミュレー

ションの文脈内に人間がプレイヤとして参加し、全面的にせよ部分的にせよ、そのプレイヤの意思決定によって動作するようなシミュレーションのことである」とゲーミングを定義づけている [21]。ここでのシミュレーションとは、現実のあるいは提案されたシステム、プロセス、環境が持つ中心的な特徴あるいは要素についての操作モデルを指す [21]。新井は、Greenblat の定義を「おそらくこの定義は多くの研究者、実務家が認める最大公約数的なものであろう」と述べている [3]。ここで注意すべきことは、Greenblat の定義が、ゲーミングに人間がプレイヤとして参加することが前提だった時代のものであるということである。20 世紀末から現在に至るまでに、情報技術が劇的に発達し、その周辺産業もまた飛躍的な進歩を遂げた。ハードウェア・ソフトウェアの両面で技術水準が驚異的な速度で進歩し、計算資源が安価となった。情報技術の発達の過程で、人間に代わってエージェントがプレイヤとしてゲーミングに参加するという試みが始まった (e.g. [22][23][24][25])。ここでエージェントとは、アルゴリズムに従って自ら意思決定を下すことを可能とするコンピュータプログラムを指す。

以上を踏まえ、本研究で扱うゲーミングの定義を以下のように定義する。この定義は、Greenblat の定義 [21] におけるプレイヤが満たすべき要件を拡張し、人間に加えてアルゴリズムに従って動作するエージェントを加えたものである。ゲーミングとは、「現実または提案されたシステムの中心的な特徴または要素についての操作モデルを備え、役割と環境を与えられた人間またはエージェントが、自律的に意思決定するプレイヤとして参加し、プレイヤ間の相互行為から成り立つシミュレーションのこと」とする。

2.2.2 ゲーミングの特徴

ゲーミングを利用することで、現実世界の複雑な現象をモデル化し、シミュレーションを通して理解することが可能になる (図 2.1) [26]。ゲーミングは、(1) 人間の反応や相互作用を予想することが困難な、人間が研究対象のシステムに組み込まれている状況を扱う探索型研究、(2) 専門家の考えを引き出すための試み、(3) 状況の本質、特に競争的状況の本質を理解するための学習あるいは研究、といった用途に適していると考えられている [26]。

Duke はゲーミングを政策の策定や組織にとって重要な意思決定をする場合に必要となる未来を言語化する手法と定義し、「未来を語る言語 (The Future's Language)」と名付けた [27]。ゲーミングは異なった世界観を保つ主体間のコミュニケーションを可




図 2.1: ゲーミングにおける表現と解釈 ([3]P.34 より転載). プレイヤーは関心対象の世界について解釈し、その上でゲーミングに取り組んで対象世界に関する内部モデルを組み換え、システムモデルも批判的検討に曝される。

能とする [28]. それ故、ゲーミングは参加型のアプローチの一種と位置付けられ、未来の技術社会システムを創造する上で、システムのステークホルダー間のコミュニケーションに欠かせないツールであるとされている [29].

以上をまとめると、ゲーミングには以下に示す3つの側面がある言える [30].

- (a) 対象タスクドメインをモデル化するという側面（モデル化の側面）
- (b) 発生し得る将来の状況を記述する言語という側面（言語としての側面）
- (c) 設計者あるいは参加者のコミュニケーションを促進する側面（コミュニケーションとしての側面）

(a) モデル化の側面では、ゲーム設計者によってゲームが開発され、実行される中で、現実世界の複雑さは捨象され、定められたルールが作り出す秩序の中で、プレイヤーに主体的な学習を可能とすることが特徴的である。ゲーミングは、Kolb が提唱する経験学習 [31] の理論的枠組に含まれており [32], 内容的に共通する点が多い [30]. 経験学習とは、「能動的実験・具体的経験」と「内省的観察・抽象的概念化」という二つの

モードが循環しながら知識が想像され、学習が生起するという考えに基づく学習モデルである [33][34].

(b) 言語としての側面では、プレイヤは、ゲーミングで経験した体験を通して、動的な状況の下でのプレイヤの組織的な行動や意思決定を、「未来の言語」[27] による記述として提示されることが特徴的である. International Simulation and Gaming Association (ISAGA) の創設者である Duke によれば、ゲーミングは、未来の言語と見做することができる. ゲーミングは、現実世界の問題状況をゲームという仮想的状況のなかで「構造化」することによって、異なった世界観をもつ主体の間でのコミュニケーションを可能とする [28]. そのため、ゲーミングは、多様な意思決定のあり方、解釈のあり方について学習するための手段となり得ると考えられている [28].

(c) コミュニケーションとしての側面では、プレイヤは現実世界が抽象化されたゲーム空間に身を投じ、背景説明・実行・省察というプロセスを体験する中で、プレイヤ間の協調的および競合的な行動を促され、プレイヤ間で対象タスクドメインの理解が促進することが重要である. ゲーミングでの体験は、プレイヤによって現実そのものと見做される [3]. プレイヤは、現実世界で獲得した知識や経験に基づいて、ゲーミングの中で提示される社会的状況に対応して意思決定する. 従って、プレイヤはその意思決定の過程の中で、各々独自の経験と学習をすることとなる.

2.2.3 ゲーミングの実行手順

ゲーミングは、ブリーフィング、ゲームプレイ、デブリーフィングの順序で実行される [4][35][36] (図 2.2).

ブリーフィングとはゲーミングの準備をすることである [35]. ブリーフィングは、ゲーミングが始まる前にプレイヤに状況の説明をし、準備をさせるために設けられている [36]. プレイヤは既存の知識を活性化させることで自らが有する既存の枠組みを解き放ち、状況への関心を高めることができる [37].

ゲームプレイとはシミュレートされた環境での相互作用のことである (すなわちゲームを実行するフェーズのこと) [35]. プレイヤはブリーフィングでの指示や説明に従い、他のプレイヤや環境と相互作用を繰り返しながらゲームをプレイする.

デブリーフィングとはプレイヤが直面したゲーミング体験についての自己および共同の内省のことである [35]. デブリーフィングにおいて、プレイヤは個人的な振り返りや、ファシリテータや他のプレイヤとの討論を行い、それぞれのゲーミング体験に関

わる知識や見解を互いに共有し合い、自らがゲーミングで体験した事柄について理解を深める [38][39]. ゲーミングの効果を高めるためには、ゲーミングの実施だけでは不十分で、デブリーフィングの実施が不可欠である [6].




図 2.2: ゲーミングの実行手順

2.3 本研究のアプローチの独自性

本節では、本研究と関連研究を比較して本研究の提案手法の優位性を示す。本研究の提案手法は、デブリーフィングへのファシリテーターによる What-If 分析の支援を目的に利用される。従って、この主旨に沿った研究を本研究の比較対象とする（図 2.3）。

ファシリテーターのファシリテーションの個人差に依存する[中村1998; Kato 2005; Crookall 2022]		エージェントにゲームをさせてログを生成したのみ	
本研究における要件	Steinwachs 1992	Yang & Tanabu 2013	提案手法
ゲームプレイのログからログのタイプを抽出できること(シナリオの抽出)	×	×	◎
ゲームプレイのログからログのタイプと類型化の要因となり得る行動を推定できること(シナリオの生成要因の推定)	×	×	◎

図 2.3: 関連研究との比較

ファシリテーターは、自らの経験から教育方法を理論化し、それぞれ独自のアプローチでファシリテーションに取り組んでいる [14][15]. デブリーフィングにおけるファシリテーションをファシリテーターはどのように実施するべきかについては、これまで長く議論されてきた。しかし、筆者が調べた限りでは、全ての議論 [40][41][42][16][15] にお

いて、デブリーフィングにおけるファシリテーションの内容やその効果はファシリテータの持つ技能に左右されるという前提が明示的・暗黙的に置かれている。従って、ファシリテータによる What-If 分析もまたファシリテータによるファシリテーションの違いに影響されると考えられる。

これに対して、近年はデブリーフィングにおける What-If 分析にエージェントシミュレーションによって得られたログを活用するという発想に基づいた研究がある [43][44]。Yang & Tanabu は被験者実験で得たログを元にエージェントを作成し、エージェントにゲーミングをプレイさせて得たログをデブリーフィングでの What-If 分析へ活用することを検討した。彼らはログからの知識抽出を視野に入れていたが、具体的な知識の抽出を試みてはいない。

最後に、これまでの議論を踏まえ、本研究における研究目的の達成が先行研究が抱える課題に対してどのように貢献するかを述べる（図 2.4）。本研究の提案手法は、デブリーフィングでファシリテータによって実施される What-If 分析を支援するための知識をゲームのログから得る手法を提案する。エージェントがプレイしたゲームのログを分析して P-GL-AA を抽出することで、ファシリテータはゲームプレイで観測され得るログの類型（シナリオ）と、ログの類型を生成する要因となり得るエージェントの行動を把握することができる。P-GL-AA はエージェントを用いたシミュレーションと、分析者の手が加わることのない発見的なログの分析手法を組み合わせることで得られる。ファシリテータが P-GL-AA をゲーミング実施の前に把握しておくことで、ゲームで起こり得るシナリオとその生成要因であるエージェントの行動についての共通認識をファシリテータ同士で共有することができる。ファシリテータが左記の共通認識に基づいてデブリーフィングに望むことで、少なくとも、What-If 分析におけるファシリテーションの内容は、同じ知識に基づいて実施できるようになることが期待できる。その結果、ファシリテーションの個人差が小さくなる可能性があるが、この問題については本研究では扱わない。

2.4 まとめ

本章では、まずゲーミングについて解説し、続いて、ゲーミングのデブリーフィングでの What-If 分析の支援を志向した研究を比較して、従来研究の問題点を議論した。議論の結果、提案手法を用いてゲームプレイのログから抽出する P-GL-AA をファシリテータがゲーミングを実施する前の段階で把握しておくことで、ファシリテータ同士の

本研究では...

- 提案手法でゲームプレイのログからP-GL-AAを抽出
- ファシリテーターは共通の知識(P-GL-AA)を前提にファシリテーションが可能になる

先行研究に対する課題

- デブリーフィングでは、個人差のあるファシリテーションの下で、What-If分析によるシナリオの検討が行われる。
 - ✓ 口頭でのコミュニケーションだけではデブリーフィングの効果は不十分[Greenaway 07]
 - ✓ プレイヤ(人間)を使ったゲーミングで十分なログを収集するのは困難[Roungas 2019]
 - ✓ 十分にログがあったとしてもファシリテーター同士の間でシナリオとその生成要因に関する共通認識の下でファシリテーションできない。
- ファシリテーターはプレイヤからのゲームに関する質問への正しい答えを知っておく必要あり[Roller1992]
 - ✓ ゲームプレイのログから得られた情報や知識はデブリーフィングでのプレイヤの学びに活用される[Crookall 2010; Johnson & Gonzalez 2008]

課題に対する貢献

- デブリーフィングへの貢献
 - ✓ ファシリテーターによるWhat-If分析を支援。
 - ✓ ファシリテーター同士の間でシナリオとその生成要因の共通認識をもたせてファシリテーションを実行できるよう支援。

図 2.4: 先行研究が抱える課題に対する研究目的の達成がもたらす貢献

間でゲームで起こり得るシナリオとその生成要因となり得るエージェントの行動について共通の認識を共有した上で、ファシリテータがデブリーフィングに臨み、What-If分析でのファシリテーションを実行できることが期待できることが示された。このことがファシリテーションの個人差を縮めることに貢献するかの確認は将来の課題である。

第3章 提案手法

3.1 はじめに

本章では、第1章で紹介した P-GL-AA (Patterns of Gaming Logs and Actions of Agents) をゲーミングのログから抽出する提案手法について説明する。これに加えて、提案手法を適用するゲームの要件を定義する。

3.2 提案手法

3.2.1 提案手法の説明

本研究では、エージェントにゲームをプレイさせて得たログを類型化してシナリオを抽出し、さらにログの類型化の要因となったエージェントの行動を明らかにするという分析手法を提案する (図 3.1)。本手法では、まず、エージェントにゲームをプレイさせる (ゲームの実行)。次に、そのログを類型化してシナリオを抽出する (ログの類型化)。最後に、ログの類型同士を比較して類型化を生じさせるエージェントの行動の要因を抽出する (類型化の行動要因の分析)。本研究では、分析の結果として明らかになった知識を P-GL-AA と呼ぶ。P-GL-AA とは、「ゲームプレイのログの類型と、その類型化の要因となり得るエージェントの行動」を指す。




図 3.1: 提案手法

P-GL-AA はゲーミングを実施する前の段階でファシリテータに与えられる。従って、ファシリテータはゲーミングを自分が実施する前に、自分がこれから扱うゲーミングのゲームプレイにおいて観測され得る複数のシナリオと、それらのシナリオを生じさせたエージェントの行動が何かを把握することができる。

3.2.2 提案手法の使用が想定されるユーザー

提案手法は、ファシリテータによる既成のゲームを用いたゲーミングを実施することが想定されるケースに適用されることを想定している。当該ケースでは、ファシリテータはゲームの利用者に過ぎず、使用対象となるゲームの詳細な仕様を把握することが困難である。従って、ファシリテータは、対象のゲームのシナリオ分析を事前に済ませるために、エージェントを自ら設計し、ゲームをプレイさせ、そのログを分析することが要求される。

3.2.3 提案手法がファシリテーションに与え得る影響

ゲーミング実施前の段階でファシリテータに P-GL-AA を把握させる狙いは、デブリーフィングでの What-If 分析におけるファシリテーションのばらつきの影響を低減させることである。第 2 章で述べた通り、ファシリテータのファシリテーションには個人差がある。そのため、ファシリテータが異なれば What-If 分析の内容やその効果にも違いが生じてしまう可能性がある。これに対して、ゲーミングを実施する前の段階で、ファシリテータに P-GL-AA を与えることで、ゲームプレイでどのようなシナリオが起り得て、どのようなエージェントの行動がシナリオを分ける可能性のある要因であるかに関して、ファシリテータ同士の認識の差異を埋めることができる。その結果、What-If 分析を実施するファシリテータは、同じ知識に基づいて仮のシナリオやそれを生成する可能性のある要因となるエージェントの行動をプレイヤに示すことができる。本研究では、P-GL-AA のファシリテータへの供与が What-If 分析に与える影響を分析することに関しては、本研究の範囲外とする。

3.3 本研究で使用するゲーム

本節では、本研究のゲーミングで使用されるゲームを定義する。

3.3.1 ゲームの基本要件と定義

Apt[45] は、「ゲームとはある目的のための制約（ルール）の下で行動する競争者（プレイヤー）の間での競争（遊び）である.」と述べた. Klabbers[46] は「ゲームとは、目的（成功、勝利、名声、地位、見返り）に向けて制約（ルールと資源）の下で行動する競争者またはプレイヤー間での競争または努力（遊び）である.」と述べた. Dorn[47] は「シミュレーションゲームは、ゲームとシミュレーションの両方の基本的な特徴を持つ演習である.」と述べた. その上で、シミュレーションゲームをゲームとシミュレーションという要素に分解した. まずゲームについて「ゲームとは、目的または目標のための制約またはルールの下で動作する敵対者またはプレイヤー間のあらゆる競争または遊びである.」と述べた. 次にシミュレーションについて「シミュレーションとは、現実の中心的特徴の操作的な表現である.」と述べた.

上で挙げたどのゲームの定義においても、ゲームは複数のプレイヤあるいは競争者の間で取り組まれる営みであると述べている. しかしながら、一般に、ゲームとは必ずしも複数人で取り組まなければ成立しないわけではない. 世の中にはプレイヤが単独で取り組むゲームとよばれる営みには枚挙に暇がない. ゲームの定義に関する議論の中には「ゲームとは一人以上のプレイヤが参加する一連の活動である」と、プレイヤ単独の参加で成立するゲームの存在を許容するものもある [48]. さらに、プレイヤ単独で参加したゲームにも、プレイヤによる自分自身との競争という意味で、競争の側面があるという指摘もある [48].

上記に挙げたゲームの定義を踏まえた上で、本研究のゲーミングで使用されるゲームを構成する要素を、目的、プレイヤー、競争・遊び、ルール、資源、制約、シミュレーションとする（図 3.2）.

ゲームの定義	ゲームの要素						
	シミュレーション	目的	プレイヤー	競争／遊び	ルール	制約	資源
Aptの定義		✓	✓	✓	✓	✓	
Klabbersの定義		✓	✓	✓	✓		✓
Dornの定義	✓	✓	✓	✓	✓	✓	
本研究の定義	✓	✓	✓	✓	✓	✓	✓

図 3.2: ゲームの構成要素の比較

その上で、「ゲームとは、シミュレーションとしての側面を持つ、目的を達成するためにルールや資源という制約の下で行動する1人のプレイヤーによる競争または遊び」と定義づける。

3.3.2 ゲームの目的

本研究が対象とするゲームの目的は、資源配分問題 [49] を解くことである。

3.3.3 シミュレーションモデル

本節では、ゲームの構成要素の一つであるシミュレーションの基本モデルについて解説する。本シミュレーションに意思決定主体として参加するエージェントは、自己資源の配分と成長という2つの機能を備えている必要があるものとした。そのため、本シミュレーションの基本モデルには「エージェントが複数の活動に自身の資源変数を配分すること」と「これらの活動を通じた資源変数の配分・成長の間に競合／強化関係のネットワーク構造が存在すること」の2つの構造を備えている必要がある。

そこで、これらの条件を満たすシミュレーションの基本モデルとして、國上の MATH モデル [50] を採用した。MATH モデルは、元々は社会・組織シミュレーションにおける、個々のエージェントによる様々な活動への事故資源配分行動を記述するモデルのアーキタイプとして提案されたものである。MATH モデルはエージェントは資源変数を備え、資源変数間には競合／強化関係が存在する。資源変数が備える第一の特性は、示量性と示強性のどちらかである。示量的な資源変数とは、加法的であり、資源配分において競合的に配分される。もしプレイヤーがある目的のために示量的な資源を配分すると、その資源は減少し、次に別の目的のために配分可能な資源は少なくなる。示強的な資源変数とは、乗法的であり、資源配分において非競合的に配分される。一方、示強的資源変数とは、乗法的であり、資源配分において非競合的に配分される。もし、プレイヤーが同時に複数の目的のために示強的な資源を配分すると、示量的な資源とは異なり、彼の資源はどの目的に対しても同様に影響を与える。資源変数に備わる第二の特性は、資源変数の値に上限があるかどうかである。資源変数の値に上限がないということは、プレイヤーが保有する資源は無制限に増加することが可能であるという意味である。一方、資源変数の値に上限があるとは、プレイヤーが保有する資源には、一定以上には増えないということである。



MATHモデルでは、資源変数間の競合・強化の相互関係を記述するため、エージェントの資源変数と活動の関係を N^2 ダイアグラム [51] (図 3.4) を援用している。 N^2 ダイアグラムはシステムエンジニアリングにおいてシステムのコンポーネント間相互の入出力のネットワーク関係を整理するために用いられる。 N^2 ダイアグラムでは、コンポーネントを要素とする隣接行列としてシステム全体の機能を表現する。しかし MATH モデルでは、その双対表現を用いてデータとしての資源変数間を繋げる機能としてのエージェントの活動を表現されている。

Input Output	金銭的資産 Money	能力 Ability	時間 Time	健康・体力 Health
Money	投資		単純労役	
	信託	雇用労働		
Ability		起業・副業		
		学び		
Time	時間を買う	時間の節約		長生き
Health	医療	トレーニング・健康増進		
資源変数の性質	競合的	非競合的	競合的	非競合的
	上限無し		上限有り	

図 3.3: エージェントの MATH モデル ([50] の図 3 より抜粋)

本研究では、上記で説明した MATH モデルを採用したシミュレーションモデルを備えたゲームを用いたゲーミングを対象とする。このモデルで表現されるシステムは M 個の入力と N 個の出力で構成される隣接行列で記述される (図 3.5)。システムに入力される資源変数の組み合わせの数 N_{IN} と、システムから出力される資源変数の組み合わせの数 N_{OUT} 、システムを構成する活動の最大数 N_{IO} を表す方程式は図 3.5 に掲載されている通りである。

本研究が対象とするゲームが扱う問題には、社会システムとプレイヤーの間で交わされる個別的な相互作用が含まれる (図 3.6 の左図) [52]。組織とプレイヤーの間で個別に

図 3.4: N^2 ダイアグラム

$$N_{IN} = \sum_{k=1}^M M C_k$$

$$N_{OUT} = \sum_{k=1}^N N C_k$$

$$N_{IO} = N_{IN} \times N_{OUT}$$

図 3.5: 本研究が対象とするゲームが扱う資源変数の関係

交わされる相互作用を考慮することにより、本研究が対象とするゲームを、企業・組織とプレイヤーの間の非対称情報化による利得最大化ゲームとみなして、プリンシパルエージェンシ問題 [53] を拡張した問題を扱うこともできる。また、社会・組織の制度を境界条件としたミクロマクロループ (図 3.6 の右図) では、エージェントの内部資源の集合的向上を制度的に誘導する問題が考えられる。この問題についてはエージェント間のランダムな相互学習における期待効用をもとにした社会学習動学モデル [54] の

拡張，あるいはより詳細なエージェントシミュレーションによるアプローチが考えられる．




図 3.6: (左図) 社会システムとプレイヤーの間の個別的相互作用を扱うゲーム，(右図) プレイヤー間のマイクロな相互作用と組織・社会とプレイヤーの集団との間におけるマクロな相互作用からなるマイクロマクロループ

ここまで，本研究が対象とするゲーミングで使用するゲームが満たすべき条件（ゲームの定義，ゲームの目的，シミュレーションモデル）を説明した．これらの条件を満たすゲームとして，ビジネスゲームのアレクサンダーアイランド [17]，ベーカリーゲーム [18] の他，本研究で用いるキャリア教育用のシンライフキャリアゲーム [55] が挙げられる．

3.3.4 ゲームおよびエージェントのモデル

本研究では，シンライフキャリアゲーム バージョン2と呼ばれるキャリア教育向けに開発されたゲームを使用する．本ゲームをエージェントにプレイさせ，そのログを分析の対象とする．

以下に，シンライフキャリアゲーム バージョン2のモデルとゲームをプレイするエージェントの仕様を記述する．ゲームとエージェントのモデルはODD プロトコル [56][57] を用いて記述される．ODD プロトコルとは，エージェントシミュレーション [58] のモデルの仕様記述の標準的手法である．エージェントシミュレーションとは，計算機シ

ミュレーション上において、エージェントと呼ばれる複数の主体の相互作用によって引き起こされる現象を分析するための手法である。ODD プロトコルは Overview, Design concepts, Detail の三要素によって構成され、それぞれについて記述すべき事柄が整理されている。第4章と第5章では、エージェントの仕様に違いがあるため、区別して説明する。

Overview および Design concepts

まず、Overview と Design concepts の内容を図 3.7 にまとめた。次に、Entities, state valuables, and scales に載せるべき状態変数の一覧を図 3.8 にまとめた。さらに、ゲームの1ラウンドにおける進行プロセスを図 3.9 に載せた。続いて、第4章の実験に使用するエージェントの行動モデルを図 3.10 にまとめた。

Detail

本節では、ゲームのモデルの詳細について記述される。Detail は Initialization, Input, Subsystems で構成される。Initialization はモデルの初期状態の仕様を記述する。Input では、モデルに対する外的なデータソースなどからの入力仕様を記述する。Submodels では、プロセス、スケジューリングにおけるサブモデルの仕様を記述する。本実験では外部データの入力を行わないため、Input は存在しない。

まず、Initialization の内容を記述する。シミュレーションの開始時に、図 4.1 の内容に基づいて状態変数と定数が初期化される。資源変数のお金資源 (M)、能力変数 (A)、時間資源 (T)、健康資源 (H) の定義域は表 3.1 の通りで、それ以外の状態変数の定義域は 0 以上である。

表 3.1: 資源変数の定義域

変数の値の範囲
$0 \leq M(t)$
$0 \leq A(t)$
$0 \leq T(t) \leq T_{MAX}$
$0 \leq H(t) \leq H_{MAX}$

最後に、プロセスとスケジューリングの Submodels を記述する。図 3.9 に基づき、第4章の実験で実行されるゲームの1ラウンドにおける処理に関して詳細に記述する。ま

概要 Overview	目的 Purpose	当該ゲームは、キャリア教育への利用を想定して開発された。当該ゲームは、就業体験やキャリア構築の経験がない学生に、労働者の立場で人生における意思決定を体験させることを目的としている。
	エンティティ、状態変数、スケール Entities, state variables, and scales	エージェントが労働者として4つの資源（お金資源、能力資源、時間資源、健康資源）を有しており、資源の配分先として5つの活動（正規雇用労働、フリーランス労働、単純労働、正規雇用労働、学習、余暇）が用意されている。正規雇用労働は日本企業の正社員の労働のように、能力資源・時間資源・健康資源を代償にお金資源を得るという活動である。フリーランス労働はフリーランサーの労働のように、能力資源・時間資源・健康資源を代償にお金資源を得るという活動である。フリーランス労働では、運次第で正規雇用労働よりも多くの（又は少ない）お金資源を得ることになる。単純労働は時間資源と健康資源を代償にしてお金を稼ぐ活動である。学習はお金資源、能力資源、時間資源、健康資源を代償に能力資源を得るという活動である。余暇とは、時間資源と健康資源を代償に健康資源を得るという活動である。最後に、健康悪化という活動がある。健康悪化は、余暇以外の活動に資源を配分すると、付随的に健康資源を失うという活動である。エージェントには活動の選択の傾向別に3種類用意され、それぞれ「必ず労働に資源を配分するタイプ（Aタイプ）」「必ず学習に資源を配分するタイプ（Aタイプ）」「必ず余暇に資源を配分するタイプ（Cタイプ）」である。
	プロセスの概要、スケジューリング Process overview and scheduling	各タイプのエージェントは、1ステップごとに必ず2つの活動を選択して資源を配分する。詳細はAppendixを参照。
設計概念 Design concepts	基本原理 Basic principles	このモデルはステップ単位で進行する数学的なモデルとして利用される。
	創発 Emergence	各資源変数の値の変化は、時系列の線グラフによって表現される。ステップが進む度にグラフの内容は更新される（詳細は「サブモデル」に記す）。
	適応 Adaptation	エージェントは適応的な行動はしない
	目標・対象 Objectives	エージェントは、一人の労働者として仮の人生を体験する。その過程で、エージェントは自らの意思に従って望ましい活動を選択し、資源を活動に分配し、自らにとって望ましい資源を増やす必要がある。
	学習 Learning	エージェントモデルには学習の機能は実装されていない。エージェント（人間）がゲームをプレイした場合、学習が起きることが期待される。
	予測 Prediction	エージェントモデルには活動への資源分配の結果の予測機能は実装されていない。
	感知 Sensing	エージェントは、ラウンドの開始直後に自分が保有する資源の過去から現在までの資源量の値を確認することができる。
	相互作用 Interaction	エージェント単体でプレイされるため、プレイヤー間のインタラクションはない。
	偶然性 Stochasticity	フリーランス労働の収入額はラウンドごとに乱数を用いて調整される。乱数の値はゲーム開始時に決定される。
	集団 Collectives	エージェント単体でプレイされるため、プレイヤー間で集団を形成することはない。
	観察 Observation	エージェントが保有する資源の値の変化とエージェントの行動タイプの関連が確認された。確認の目的は、Aタイプの労働（正規雇用労働、フリーランス労働、単純労働）を中心に資源を多く配分するエージェントが、お金資源をより多く得るという自明な結果とならないことを確認するためである。


図 3.7: シンライフキャリアゲーム バージョン2 とエージェントの仕様（第4章の実験に対応）

状態変数(1列目)	記号	範囲	状態変数(2列目)	記号	範囲
お金資源	$M(t)$	$0 \leq$	健康被害	$H_{BRDW}(t)$	$[0, 100]$
能力資源	$A(t)$	$1 \leq$	自己投資支出	$M_{LN}(t)$	$[0, 50]$
時間資源	$T(t)$	$[0, 100]$	労働時間(正規雇用)	$T_{PW}(t)$	$[0, 100]$
健康資源	$H(t)$	$[0, 100]$	労働時間(フリーランス労働)	$T_{FW}(t)$	$[0, 100]$
収入(正規雇用労働)	$I_{PW}(t)$	$0 \leq$	労働時間(単純労働)	$T_{SW}(t)$	$[0, 100]$
収入(フリーランス労働)	$I_{FW}(t)$	$0 \leq$	学習時間	$T_{LN}(t)$	$[0, 100]$
収入(単純労働)	$I_{SW}(t)$	$0 \leq$	余暇時間	$T_{LS}(t)$	$[0, 100]$
成長(正規雇用労働)	$G_{PW}(t)$	$0 \leq$	収入調整	$\varepsilon_{FW}(t)$	$[\alpha, \beta]$
成長(学習)	$G_{LN}(t)$	$0 \leq$	健康状態の活動への影響	$\gamma_H(t)$	$[0, 1]$
健康回復	$H_{RCV}(t)$	$0 \leq$			

図 3.8: シンライフキャリアゲーム バージョン 2 のモデルで使用する状態変数 (第 4 章と第 5 章の実験間で共通の内容)

概要: プロセスの概要, スケジューリング

- 最初のラウンドの初期化プロセス
 - ✓ ゲーム開始後の初期設定で行われる.
 - ✓ 2ラウンド以降の全ラウンドで, 当該プロセスはスキップされる.
- プレイヤーの行動: 保有する資源の量を確認する.
- プレイヤーの行動: 活動への資源配分を選択する.
 - ✓ プレイヤーは5つの異なる活動(正規雇用労働, フリーランス労働, 単純労働, 学習, 余暇)に資源を配分することができる.
- 新たに活動に配分された資源量に基づく資源の生産量の計算
- プレイヤーの保有する資源量の更新



1ラウンド内のシーケンスプロセス

図 3.9: 1 ラウンドにおける処理の流れ (第 4 章の実験に対応)




図 3.10: エージェントの資源配分の意思決定手順（第 4 章の実験に対応）

ず、ゲームが開始された直後は、「最初のラウンドの初期化プロセス」から始まる。ここでは、Initialization で説明した通り、状態変数と定数が初期化される。次に、「エージェントの行動：保有する資源の量を確認する。」の処理に移り、エージェントは自らが保有する資源変数の値を確認できる。その後、「エージェントの行動：活動への資源配分を選択する」の処理に移る。エージェントは、前のフェーズで確認した情報を元に検討し、各種活動への資源配分を行う。

ここからは、第 5 章の実験で使用するエージェントのモデルについて説明する。第 5 章の実験で使用するエージェントの行動モデルは、第 4 章の実験で使ったエージェントの行動モデルと異なる 2 点がある。第一に、エージェントの意思決定モデルが異なる。エージェントはステップごとに GP・BP・IP という 3 つの行動のいずれかから 1 つを選ぶ点である（図 3.11 と図 3.12）。GP を「労働重視型の行動」と呼び、エージェントは正規雇用労働に主に時間資源を費やす。そして、余った全ての時間資源を余暇に充てる。この行動は、出世に関心はないが勤労な正規雇用労働者を模倣して設計された。BP を「バランス型の行動」と呼び、エージェントは正規雇用労働、学習、余暇に満遍なく時間資源を充てる。この行動は、出世のために自己投資に励む正規雇用労働者を模倣して設計された。IP を「余暇重視型の行動」と呼び、エージェントは正規雇用労働に最低限の時間資源を充て、残りの時間資源を全て余暇に充てる。この行動は、プライベートの時間を重視するタイプの正規雇用労働者を模倣して設計された。第二に、健康資源への反応である。エージェントは、健康資源変数の値が一定の

値を下回ると、余暇に優先的に資源を配分するよう行動する（IP を必ず選択する）。そして、健康資源変数の値が最大に達したら、再び IP 以外の行動を選択することを可とする。エージェントの意思決定手順を図 3.13 に示す。

ここからは、「新たに活動に配分された資源量に基づく資源の生産量の計算」の処理について記述する。

エージェントが正規雇用労働で得る収入は、能力資源を多く保有し、労働資源を多く費やすほど高額となる（式 (3.1)）。

$$I_{PW}(t) = c_{PW} \times A(t-1) \times T_{PW}(t) \quad (3.1)$$

エージェントが正規雇用労働で得る能力資源は、能力資源を多く保有し、労働に費やす時間資源が多いほど多くなる。ただし、健康資源が少ないほど、得られる能力資源は減る（式 (3.2)）。

$$G_{PW}(t) = \gamma_H(t) \times c_{gPW} \times T_{PW}(t) \times A(t-1) \quad (3.2)$$

エージェントがフリーランス労働で得る収入は、能力資源が多く、労働時間が長い程高額になり易い。ただ、健康資源が少ないと収入が減る。また、ランダム値をとる係数の値次第で、大幅に収入が増えたり減ったりする（式 (3.3)）。

$$I_{FW}(t) = \gamma_H(t) \times \epsilon_{FW} \times c_{FW} \times T_{FW}(t) \times A(t-1) \quad (3.3)$$

エージェントが単純労働で得る収入は、労働に費やす時間資源が多いほど高額となる（式 (3.4)）。

$$I_{SW}(t) = \gamma_H(t) \times c_{SW} \times T_{SW}(t) \quad (3.4)$$

エージェントが学習で得る能力資源は、学習に費やすお金資源、能力資源、時間資源が多いほど、得られる能力資源は増える。ただし、健康資源が少ないほど、得られる能力資源は減る（式 (3.5)）。

$$G_{LN}(t) = \gamma_H(t) \times c_{gLN} \times T_{LN}(t) \times M_{LN}(t)^n \times A(t-1) \quad (3.5)$$

エージェントが労働や学習に費やした時間資源が多い程、健康資源は減る（式 (3.6)）。

$$H_{BRDW}(t) = c_{BRDW} \times (T_{PW}(t) + T_{FW}(t) + T_{SW}(t) + T_{LN}(t)) \quad (3.6)$$

概要 Overview	目的 Purpose	第4章の実験に従う
	エンティティ, 状態変数, スケール Entities, state variables, and scales	エージェントが労働者として4つの資源（お金資源, 能力資源, 時間資源, 健康資源）を有しており, 資源の配分先として5つの活動（正規雇用労働, フリーランス労働, 単純労働, 正規雇用労働, 学習, 余暇）が用意されている。正規雇用労働は日本企業の正社員の労働のように, 能力資源・時間資源・健康資源を代償にお金資源を得るという活動である。フリーランス労働はフリーランサーの労働のように, 能力資源・時間資源・健康資源を代償にお金資源を得るという活動である。フリーランス労働では, 運次第で正規雇用労働よりも多くの（又は少ない）お金資源を得ることになる。単純労働は時間資源と健康資源を代償にしてお金を稼ぐ活動である。学習はお金資源, 能力資源, 時間資源, 健康資源を代償に能力資源を得るという活動である。余暇とは, 時間資源と健康資源を代償に健康資源を得るという活動である。最後に, 健康悪化という活動がある。健康悪化は, 余暇以外の活動に資源を配分すると, 付随的に健康資源を失うという活動である。 <u>エージェントはGP・BP・IPという3つの行動のいずれかからステップごとに1つ選択する。GPは労働重視型の行動。BPはバランス型の行動。IPは余暇重視型の行動をとる。</u>
	プロセスの概要, スケジューリング Process overview and scheduling	第4章の実験に従う
設計概念 Design concepts	基本原理 Basic principles	第4章の実験に従う
	創発 Emergence	各資源変数の値の変化は, 時系列の線グラフによって表現される。ステップが進む度にグラフの内容は更新される（詳細は「サブモデル」に記す）。
	適応 Adaptation	<u>エージェントモデルは健康資源変数の値が一定の値を下回ると, 休暇に優先的に資源を配分するよう行動を改める。その後, 健康資源の値が最大値に達した後は, 行動を元に戻す。</u>
	目標・対象 Objectives	第4章の実験に従う
	学習 Learning	第4章の実験に従う
	予測 Prediction	第4章の実験に従う
	感知 Sensing	第4章の実験に従う
	相互作用 Interaction	第4章の実験に従う
	偶然性 Stochasticity	第4章の実験に従う
	集団 Collectives	第4章の実験に従う
	観察 Observation	第4章の実験に従う

図 3.11: シンライフキャリアゲーム バージョン 2 とエージェントの仕様（第 5 章の実験に対応）

概要: プロセスの概要, スケジューリング

1. 最初のラウンドの初期化プロセス
 - ✓ゲーム開始後の初期設定で行われる.
 - ✓2ラウンド以降の全ラウンドで, 当該プロセスはスキップされる.
2. プレイヤの行動: 保有する資源の量を確認する.
3. プレイヤの行動: 活動への資源配分を選択する.
- ✓プレイヤはGP・BP・IPという3つの行動のいずれか一つを選択して, 5つの活動(正規雇用労働, フリーランス労働, 単純労働, 学習, 余暇)に資源を配分する.
4. 新たに活動に配分された資源量に基づく資源の生産量の計算
5. プレイヤの保有する資源量の更新

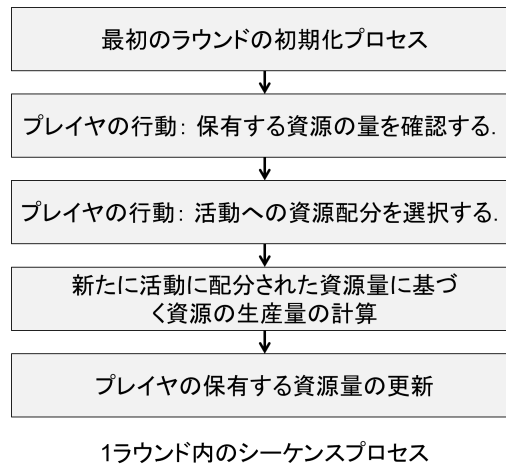


図 3.12: 1 ラウンドにおける処理の流れ (第 5 章の実験に対応)




図 3.13: エージェントの意思決定手順 (第 5 章の実験に対応)

エージェントが余暇に費やす時間資源が多いほど、得られる健康資源は増える（式 (3.7)）。

$$H_{RCV}(t) = c_{RCV} \times T_{LS}(t) \quad (3.7)$$

3 ラウンド以降、ステップ t 時点の正規雇用労働、フリーランス労働、単純労働、学習への資源配分で得られる資源の値は、2 ステップ前の健康資源変数 $H(t-2)$ の値に対する健康資源変数 $H(t)$ の初期値 $H(0)$ に対する割合 $\gamma_H(t)$ で決まる（式 (3.8)）。

$$\gamma_H(t) = \begin{cases} 1 & (1 \leq t \leq 2) \\ \frac{H(t-2)}{H_{MAX}} & (2 < t \leq 40) \end{cases} \quad (3.8)$$

あるラウンドでエージェントが保有するお金資源の総量は、直前ラウンド終了時点におけるお金資源に、労働で得たお金資源を加え、学習に費やしたお金資源を減じて得る（式 (3.9)）。

$$M(t) = M(t-1) + I_{PW} + I_{FW} + I_{SW} - M_{LN} \quad (3.9)$$

あるラウンドでエージェントが保有する能力資源の総量は、直前ラウンド終了時点における能力資源に、労働や学習で得た能力資源を加えて得る（式 (3.10)）。

$$A(t) = A(t-1) + G_{PW} + G_{LN} \quad (3.10)$$

あるラウンドでエージェントが保有する時間資源の総量は、エージェントが保有可能な時間資源の最大値から活動に費やした全時間資源を減じて得る（式 (3.11)）。

$$T(t) = T_{MAX} - (T_{PW} + T_{FW} + T_{SW} + T_{LN} + T_{LS}) \quad (3.11)$$

あるラウンドでエージェントが保有する健康資源の総量は、直前ラウンド終了時点における健康資源に、余暇で得た健康資源を加え、他の活動に資源配分をしたことで間接的に減ることになった健康資源を減じて得る（式 (3.12)）。

$$H(t) = H(t-1) + H_{RCV}(t) - H_{BRDW}(t) \quad (3.12)$$

3.4 まとめ

本章では、まず、本研究の提案手法である「P-GL-AA をエージェントがプレイしたゲームのログから特定する手法」について説明し、さらに提案手法の使用者および提案手法が適用されるゲームの要件を記述した。本提案手法により、ゲームプレイで起こり得るシナリオと、シナリオを生成する要因となり得るエージェントの行動に関するファシリテータ同士の間で、ゲームプレイで起こり得るシナリオとその生成要因となり得るエージェントの行動に関する共通の知識を共有可能になると期待できる。

第4章 DEAを用いたゲーミングからの知識抽出手法

4.1 はじめに

本章では、本研究の提案手法がエージェントがプレイしたゲームのログから P-GL-AA (Patterns of Gaming Logs and Actions of Agents) を明らかにするにあって、ログからログの類型が推定可能であることを示す。本実験ではシンライフキャリアゲームバージョン2をエージェントにプレイさせ、そのログからシナリオを抽出する。

4.2 実験計画

本節では、エージェントにプレイさせたゲームのログからログの類型の抽出可能性を確かめる実験について述べる。以下、実験で使用するゲーム、ゲームをプレイするエージェント、ゲームを実行する計算機環境、実験計画、ログの分類方法、実験結果、考察の順に説明する。最後に、本実験をまとめる。

4.2.1 ゲームおよびエージェントのモデル

本実験では、3.3.4節で説明したシンライフキャリアゲームバージョン2とエージェントを使用した。

4.2.2 計算機環境

本実験で使用するゲーミングの使用環境は、Python3で記述されたソフトウェアを、Windows10 Home 64bit OS上で実行することで、実現したものである。

4.2.3 実験手順

本実験では、ユニークな乱数シードを用いて、12体のエージェントにゲームをそれぞれ1回ずつプレイさせた。ゲームは、1ゲームあたり50ラウンドずつ実施した。ゲームを実施する際に使用した状態変数と定数の初期値を図に4.1示す。その後、ログをデータ包絡分析法（DEA）[59]を用いて分類した。

状態変数	初期値	変数	初期値	定数	初期値
$M(t)$	0	$H_{BRDW}(t)$	0	c_{PW}	5.5
$A(t)$	1	$M_{LN}(t)$	0	c_{FW}	5.5
$T(t)$	100	$T_{PW}(t)$	0	c_{SW}	5.5
$H(t)$	100	$T_{FW}(t)$	0	cg_{PW}	$2.0e^{-4}$
$I_{PW}(t)$	0	$T_{SW}(t)$	0	cg_{LN}	$2.0e^{-4}$
$I_{FW}(t)$	0	$T_{LN}(t)$	0	c_{BRDW}	$5.0e^{-2}$
$I_{SW}(t)$	0	$T_{LS}(t)$	0	c_{RCV}	$2.8e^{-1}$
$G_{PW}(t)$	0	$\varepsilon_{FW}(t)$	0	n	0.50
$G_{LN}(t)$	0	$\gamma_H(t)$	1	A	$2.5e^{-1}$
$H_{RCV}(t)$	0			B	2.0

図 4.1: 状態変数と定数の初期値

4.2.4 ログの分類方法

本実験では、データ包絡分析法（DEA）を用いる。

データ包絡分析法（DEA）

DEAの基本的なモデルであるCCRモデルについて説明する。DEAは意思決定主体（DMU）の入出力の効率性を測定するために利用できる。CCRモデルを用いた分析では、まず、各DMUの入出力データがあることを確認し、次に、各DMUの入出力項の重みを分数計画法または線形計画法で調節して効率性スコアを求め、DMU間で比較し、最後に、非効率的なDMUを、より高い効率性を有するDMUの参照集合によって特徴づける、という手続きで分析が進む。多入力多出力システムの効率性を測定する際の重み付けの問題が自動的に解決されることは、DEAの利点の一つである。

以下の説明において、評価の対象となる N 個の意思決定主体を $DMU_j (j = 1, 2, \dots, N)$ で表す。さらに、それぞれの $DMU_j (j = 1, 2, \dots, N)$ に対して、 M 種の入力変数 x_{mj} と

L 種の出力変数 y_{lj} を観測済みであるとする．これらを行列式で記述すると，式 (4.1) や式 (4.2) のように， $L \times N$ の行列 X と $L \times N$ の行列 Y に蓄えられたデータとみなせる．

$$X = \begin{bmatrix} x_{11} & x_{12} & \cdots & x_{1N} \\ x_{21} & x_{22} & \cdots & x_{2N} \\ \vdots & \vdots & & \vdots \\ x_{M1} & x_{M2} & \cdots & x_{MN} \end{bmatrix} \quad (x_{mj} > 0 \quad (\forall j, \forall m)) \quad (4.1)$$

$$Y = \begin{bmatrix} y_{11} & y_{12} & \cdots & y_{1N} \\ y_{21} & y_{22} & \cdots & y_{2N} \\ \vdots & \vdots & & \vdots \\ y_{L1} & y_{L2} & \cdots & y_{LN} \end{bmatrix} \quad (y_{lj} > 0 \quad (\forall j, \forall l)) \quad (4.2)$$

まず，入力データと出力データが 1 種類ずつという最もシンプルな入出力系における効率性を簡単に定義する． $L = 1, M = 1$ のときの効率性は式 (4.3) で表され，効率値の大きい順に効率的であると評価する．

$$Efficiency = \frac{output}{input} \quad (4.3)$$

一般的な入出力系は，入力項と出力項のいずれか，あるいはその両方が複数となる特徴を有する．このような複雑な条件下での効率性を式 (4.4) 次のように定義する．

$$Efficiency = \frac{weighted \text{ sum of outputs}}{weighted \text{ sum of inputs}} \quad (4.4)$$

上記の定義では，重みの集合を定義するべきだが，これは難しい．これに対して，CCR モデルでは，分析対象の意思決定主体 DMU_j の効率性 Θ_j を次の分数計画問題として定式化した．この問題を解くことで， DMU_j の効率性スコアを求めることができる．

$\langle FP_j \rangle$

$$\begin{aligned} &\text{maximize} && \Theta_j = \frac{\sum_{l=1}^L u_l y_{lj}}{\sum_{m=1}^M v_m x_{mj}} \\ &\text{subject to:} && \frac{\sum_{l=1}^L u_l y_{lj}}{\sum_{m=1}^M v_m x_{mj}} \leq 1 (j = 1, 2, \dots, N) \end{aligned} \quad (4.5)$$

$$v_m \geq 0 \quad (m = 1, 2, \dots, M)$$

$$u_l \geq 0 \quad (l = 1, 2, \dots, L)$$

このとき、重み u_j , v_j はどのようにでも動かせるため、効率 Θ_j の値もまた重み u_j と v_j の値次第で変わる。そこで、効率性 Θ_j の上限を $1(\Theta_j \leq 1)$ で共通化した上で、それぞれの DMU_j の効率性 Θ_j の値を最大化する重み u_j , v_j を選択する。 DMU_j が他の DMU と比較して効率的な場合は Θ_j の値は 1 となり、逆に効率的でない場合は 1 より小さな値をとる。

ここで、仮に DMU_o が非効率的であるとする。また、このとき、 DMU_o の入力 of 最適な重みを v^* 、出力の最適な重みを u^* 、 v^* と u^* から導出される入出力の効率性を θ^* とする。方程式の左辺と右辺を等しくする DMU_j を DMU_o の参照集合 E_o と呼ぶ。この参照集合 E_o は、 DMU_j の効率性を改善する上で参考となる。

$$E_o = \left\{ j \left| \sum_{l=1}^L u_l^* y_{lj} = \sum_{m=1}^M v_m^* x_{mj}, j = 1, 2, \dots, N, j \neq o \right. \right\} \quad (4.6)$$

ここまで説明してきた DEA の最適化は、分数計画問題として定式化されているが、実務上はこれと等価な線形問題に変換して解かれる。

<LP_j>

$$\begin{aligned} &\text{maximize} && \Theta_j = \sum_{l=1}^L u_l y_{lj} && (4.7) \\ &\text{subject to:} && \sum_{m=1}^M v_m x_{mj} = 1 \\ & && \sum_{l=1}^L u_l y_{lj} \leq \sum_{m=1}^M v_m x_{mj} (j = 1, 2, \dots, N) \\ & && v_m \geq 0 \quad (m = 1, 2, \dots, M) \\ & && u_l \geq 0 \quad (l = 1, 2, \dots, L) \end{aligned}$$

DEA による効率性分析では、サンプル (DMU) の数が多い方が望ましいと考えられている [60]。経験則として、DEA を用いた分析では次式 4.8 を満たすことが推奨されている。 NUM_{DMU} は DMU の数、 M は入力データの数、 R は出力データの数である。

$$NUM_{DMU} = \max\{M \times R, 3 \times (M + R)\} \quad (4.8)$$

DEA を用いることの利点の一つが，このように多入力多出力系の効率性を比較する際の重みをどう決めるかという問題が，上記の最適化のプロセスで，自動的に解決できることにある．

以下では，データの分類手法としての DEA について述べる．データ分類の方法論として，DEA はクラスター分析などの距離に基づく分類手法とは異なるアプローチをとる（図 4.2）．DEA では，与えられた DMU_j の参照集合 E_j は DMU_j を改善するための参照対象である．また，効率的な DMU の参照集合はそれ自体でもある．入出力変数の空間に DMU の散布図を描くと，DMU の包絡線は全ての効率的な DMU によって形作られる．効率的な DMU と原点を含む最小の凸領域には，効率的な DMU を参照集合とする非効率的な DMU も含まれる．したがって，この一連の DMU は同じ参照集合を共有しているとみなして，同一のグループに分類できる．




図 4.2: 効率的な DMU（参照集合）で包絡線を分割して効率的でない DMU を分類可能

Kunigami らは，DEA を分類器として利用する上での利点を 2 つ挙げている [61]．DEA を分類器として使用する利点の一つは，あるグループに属する DMU 同士の優劣

関係が、機械的かつ内生的に抽出できることである。分析者が DEA を使って同じ参照集合を持つ DMU 同士の効率をそれぞれ最適化すると、互いに似通った構成の重み集合を持つ DMU の集合が機械的に出力できる。その結果、あるグループに属する効率的な DMU（参照集合であり、最適な重み集合を有する）と、その他の非効率的な DMU の優劣を表す関係が内生的に抽出できる。このことは、分類器としての DEA を使用する上で利点となる。DEA を分類器として使用するもう一つの利点は、グループの類似性の判別が容易であることである。2つの参照集合に属する DMU の間で重複する DMU の数は、両グループ間の類似性の高さを示す。両グループ間で共通する参照集合が多いほど、両グループは近いと言える。

DEA は比較的均質な組織単位 (多入力多出力システム) の間で入出力の比率 (効率性 Θ) を比較する手法である。DEA を適用できる対象は、地方自治体、学校、病院、店舗、銀行支店など多岐に渡る [60]。シミュレーションのログの類型化を目的とした利用実績も報告されている [62][63][64][65][66][67]。ゲーミングへの適用事例としては Koltai らの研究 [68][69] が挙げられる。Koltai らはプレイヤー (人間) がプレイするゲームのログの分析に DEA を適用しているが、分析結果をデブリーフィングのファシリテーションに活かすことは念頭にないため、本研究とは研究の目的が異なる。

4.2.5 実験結果

各エージェントの入出力データを表 4.1 にまとめた。入出力の基本的な統計量を表 4.2 にまとめた。なお、 $AcmT_{WK}$ は各種労働に配分した時間資源の累積値、 $AcmT_{LN}$ は学習に配分した時間資源の累積値、 $AcmT_{LS}$ は余暇に配分した時間資源の累積値、 $AcmM_{INC}$ は獲得したお金資源の累積値をそれぞれ表す。以下の DEA の分析結果 (表 4.3 を参照) を生成するために、pyDEA[70][71] という DEA ツールを使用した。

表 4.3 によれば、最も効率的なエージェント (DMU) は、 $DMU0 \cdot DMU2 \cdot DMU8$ であった。また、DEA によってゲームログはグループ X・グループ Y・グループ Z に分類された。グループ X は、 $DMU0$ と $DMU2$ を参照集合とし、 $DMU3$ のみで構成された。グループ Y は、 $DMU0$ と $DMU8$ を参照集合とし、 $DMU1$, $DMU4$, $DMU6$, $DMU7$ で構成された。グループ Z は、 $DMU8$ を参照集合とし、 $DMU5$, $DMU9$, $DMU10$, $DMU11$ で構成された。各グループに属するエージェント (DMU) を表 4.4 にまとめた。

表 4.1: ゲーミングの結果（資源の入出力）. $AcmT_{WK}$ は累積労働時間, $AcmT_{LN}$ は累積学習時間, $AcmM_{INC}$ は累積収入額を指す.

DMU #	ゲーミングの結果 [†]			
	入力			出力
	$AcmT_{WK}$	$AcmT_{LN}$	$AcmT_{LS}$	$AcmM_{INC}$
0	3.39.E+03	3.60.E+02	2.50.E+02	2.67.E+04
1	2.62.E+03	6.10.E+02	7.70.E+02	1.94.E+04
2	3.61.E+03	1.00.E+02	2.90.E+02	1.10.E+04
3	3.29.E+03	3.20.E+02	3.90.E+02	1.56.E+04
4	1.89.E+03	7.00.E+02	1.41.E+03	2.01.E+04
5	1.23.E+03	9.50.E+02	1.82.E+03	1.41.E+04
6	1.41.E+03	5.90.E+02	2.00.E+03	7.60.E+03
7	1.32.E+03	7.60.E+02	1.92.E+03	9.86.E+03
8	1.84.E+03	1.28.E+03	8.80.E+02	3.01.E+04
9	1.63.E+03	1.28.E+03	1.09.E+03	1.52.E+04
10	1.31.E+03	1.76.E+03	9.30.E+02	7.04.E+03
11	1.64.E+03	1.41.E+03	9.50.E+02	1.97.E+04

表 4.2: 入出力の基本的な統計量

<i>Statics</i>	$AcmT_{WK}$	$AcmT_{LN}$	$AcmT_{LS}$	$AcmM_{INC}$
Mean	2.10.E+03	8.43.E+02	1.06.E+03	1.64.E+04
S.D.	8.86.E+02	5.01.E+02	6.16.E+02	7.22.E+03
Variance	7.85.E+05	2.51.E+05	3.79.E+05	5.21.E+07
Median	1.74.E+03	7.30.E+02	9.40.E+02	1.54.E+04
Max	3.61.E+03	1.76.E+03	2.00.E+03	3.01.E+04
Min	1.23.E+03	1.00.E+02	2.50.E+02	7.04.E+03

表 4.3: DEA による分析結果（効率および参照集合）

DMU #	効率 Θ	参照集合	重み			
			入力			出力
			v_{TWK}	v_{TLN}	v_{TLS}	u_I
0	1.00	{0, 8}	2.38.E-04	5.38.E-04	0.00.E+00	3.74.E-05
1	0.765	{0, 8}	2.50.E-04	5.66.E-04	0.00.E+00	3.93.E-05
2	1.00	{0, 2}	1.21.E-04	5.63.E-03	0.00.E+00	9.12.E-05
3	0.646	{0, 2}	5.51.E-05	2.56.E-03	0.00.E+00	4.15.E-05
4	0.910	{0, 8}	2.88.E-04	6.51.E-04	0.00.E+00	4.53.E-05
5	0.700	{8}	8.13.E-04	0.00.E+00	0.00.E+00	4.97.E-05
6	0.436	{0, 8}	3.64.E-04	8.24.E-04	0.00.E+00	5.73.E-05
7	0.510	{0, 8}	3.29.E-04	7.44.E-04	0.00.E+00	5.18.E-05
8	1.00	{0, 8}	2.11.E-04	4.78.E-04	0.00.E+00	3.32.E-05
9	0.571	{8}	6.13.E-04	0.00.E+00	0.00.E+00	3.75.E-05
10	0.328	{8}	7.63.E-04	0.00.E+00	0.00.E+00	4.67.E-05
11	0.736	{8}	6.10.E-04	0.00.E+00	0.00.E+00	3.73.E-05

表 4.4: DEA による分析結果（ログの種類と類型を構成するログ）

グループ	参照集合	DMU
X	{0, 2}	3
Y	{0, 8}	1, 4, 6, 7
Z	{8}	5, 9, 10, 11




図 4.3: グループ X に属するログデータの分布

4.2.6 提案手法と DEA を使用した理由

DEA はオペレーションズリサーチを代表とする分析手法である。その DEA が提案手法の評価のための実験で適用することにした理由を以下に述べる。

ログの類型化

本実験の目的は、エージェントによるゲームプレイのログからログの類型（シナリオ）が抽出可能であることを確かめることである。従って、本実験では、DEA はログを類型化させるツールとして利用されている。

ログの分析結果への分析者の意図の影響の排除

提案手法はファシリテーションの違いによる What-If 分析に与える影響の低減に向けて開発された。そのため、ログの分析結果に分析者であるファシリテータの意図が影響することがないように配慮する必要がある。これを満たすログの類型化手法として DEA が適している。




図 4.4: グループ Y に属するログデータの分布

4.2.7 考察

シンライフキャリアゲーム version 2 から得られたログを DEA で分析した結果、ログは全部で 3 つのグループに分類され、それぞれのグループの参照集合と DMU の構成が明らかになった。各グループの参照集合は、同グループに属する非効率的な DMU にとって、効率を改善する上で参考になりうる。以下では、各グループの評価基準の構造を明らかにし、各グループに属する非効率的な DMU の評価を高める方法が何かについて考察する。

まず、グループ X のデータについて考察する (図 4.3)。グループ X に属する DMU #3 の $AcmT_{WK}$ の重み $v_{AcmT_{WK}}$ と $AcmT_{LN}$ の重み $v_{AcmT_{LN}}$ の値がいずれも正であるが、前者の重みの値は後者の約 2% 程度の大きさであり、 $v_{AcmT_{WK}}$ の影響は小さい。従って、グループ X では、累積学習時間 (入力) に対する累積収入額 (出力) の効率の高さを基準に、DMU が評価できることがわかった。つまり、グループ X では、ゲーミングを通して労働に割いた時間が少なく、総収入額が大きい程、DMU の効率が優れていることがわかった。




図 4.5: グループ Z に属するログデータの分布

グループ X の参照集合である DMU#2 の効率の評価基準は、DMU#3 と似ている。DMU#3 のケースと同様に、DMU#2 の $v_{AcmT_{WK}}$ と $v_{AcmT_{LN}}$ の値はいずれも正であるが、前者の重みの値は後者の約 2% 程度の大きさであり、従って、 $AcmT_{WK}$ の影響は小さい。つまり、DMU#2 はグループ X と同様の評価基準において、その効率が最適であると DEA によって評価されたのである。

これに対して、グループ X の参照集合である DMU#0 の評価基準は異なる。DMU#0 は累積学習時間の重みの値の大きさに対して、累積労働時間の重みの値の大きさは約 44% と、DMU#2 よりも累積労働時間の影響力が大きい。従って、DMU#0 は、ゲーミングを通して労働と学習に割いた時間が少なかった割には、多くのお金を儲けた DMU が高く評価されたのである。

グループ X に関する上記の考察を踏まえると、グループ X に属する非効率的な DMU の効率を改善するには、2 つの選択肢があることがわかった。第一の選択肢は、現在の行動方針を変えずに、より優れた成績を出した DMU#2 の行動から学ぶというアプローチである。第二の選択肢は、DMU#0 を参考にして現在の行動方針を修正し、労

働と学習の両方への資源配分を考慮した行動方針に変更するというアプローチである。

次に、グループ Y の実験結果を考察する (図 4.4)。グループ Y に属する DMU の $v_{AcmT_{WK}}$ と $v_{AcmT_{LN}}$ の値はいずれも正であり、前者の重みの値は後者の約 44% 程度の大きさであることから、 $AcmT_{WK}$ と $AcmT_{LN}$ の $AcmINC$ への影響はいずれも無視できない。従って、グループ Y では、累積労働時間 (入力) と累積学習時間 (入力) に対する累積収入額 (出力) の効率の高さを基準に、DMU を評価できることがわかった。言い換えれば、グループ Y では、ゲーミングを通して労働と学習に割いた時間が少なかった割には、多くのお金を稼いだ DMU が高く評価されたのである。

これに対して、グループ Y の参照集合である DMU#8 の効率の評価基準は、グループ Y のものとは異なる。DMU#8 は、累積学習時間の重みの値はゼロであり、一方で累積労働時間の重みの値は正である。従って、DMU#8 は、ゲーミングを通して労働に割いた時間が少なかった割には多くのお金を儲けたことで、高く評価されたのである。

グループ Y に関する上記の考察を踏まえると、グループ Y に属する非効率的な DMU の効率を改善するには、2 つの方向性があることがわかった。第一に、現在の行動方針を変えずに、より優れた成績を出した DMU#0 の行動から学ぶというアプローチがある。第二に、DMU#8 を参考にして現在の行動方針を修正し、労働への積極的な資源配分を志向するアプローチである。

最後に、グループ Z の実験結果を考察する (図 4.5)。グループ Z に属する DMU の $v_{AcmT_{WK}}$ の値は正であるが、 $v_{AcmT_{LN}}$ の値はゼロであった。従って、グループ Z では、累積労働時間 (入力) に対する累積収入額 (出力) の効率の高さを基準に、DMU が評価されたことがわかった。言い換えれば、グループ Z では、ゲーミングを通して労働に割いた時間が少なかった割には、多くのお金を稼いだ DMU が高く評価されたのである。

以上の議論から、ゲーミングから出力された 12 個のログを DEA で類型化することが可能であることが示された。また、ログの類型を構成するログ同士を効率性の高さに基づいて比較できることも示された。デブリーフィングにおけるシナリオの検討の場では、ゲームにおける特徴的なプロセスを明らかにすることが重要である [8]。本実験で得られたログの類型 (シナリオ) は正しくゲームにおける特徴的なプロセスに他ならない。ファシリテータは、デブリーフィングにおけるシナリオの検討の場で、プレイヤーにゲームプレイで起こり得るシナリオ (ログの類型) を示すことができる。これに加えて、プレイヤー (エージェント) のログにプレイヤー (人間) のログを加えてあらためて DEA で分析することで、プレイヤー (人間) のログがどの類型に位置づけられる

かを知ることでもできる (図 4.6).




図 4.6: DEA を用いてエージェントと人間の間でログの効率性を比較することが可能

本実験では、DEA をログの類型化の手段として利用した。その他、ログの類型化手法の候補としては、DEA の他に階層型クラスタリング法のような機械学習を用いた類型化手法も利用することができる。しかし、双方の間では、ログの類型化の結果には決定的な違いがある。DEA を用いたログの類型化では、類型に含まれるログ同士を入力・出力に関する効率性の差に基づいて比較することができる。ファシリテータは、類型とその生成要因のエージェントの行動に加えて、ログ同士の効率性に関する差異を把握した上で、What-If 分析に臨むことができる。その際、プレイヤー（人間）のログを類型に位置づけ、個別のプレイヤーのゲームプレイの結果とシナリオ分析の結果を関連付けて説明することができる。その一方で、機械学習によるクラスタリング手法を用いたログの類型化では、類型に含まれるログ同士の比較はできない。

最後に、本実験では研究の目的を達成できることを示すため、入力変数×2, 出力変数×1, ログ数×12 という比較的簡易な条件で実験を行った。しかし、当然のことながら、入力変数と出力変数をさらに増やしてより複雑な問題を扱うこともできるが、評価が複雑となるため、本研究では扱わない。こちらに関しては将来の課題とする。

4.3 まとめ

本章では, 本研究の提案手法がエージェントがプレイしたゲームのログから P-GL-AA を抽出するにあって, ログからログの類型が抽出可能であることを検証した. シンライフキャリアゲーム バージョン 2 をエージェントにプレイさせ, そのログを DEA を用いて類型化することで, ログの類型が得られることを示した.

第5章 ログクラスタ分析を用いたゲーミングからのシナリオ分岐要因の抽出手法

5.1 はじめに

本研究の提案手法がエージェントがプレイしたゲームのログから P-GL-AA (Patterns of Gaming Logs and Actions of Agents) を抽出するには、ログの類型が抽出可能である（第4章）だけでなく、ログの類型化の要因となり得るエージェントの行動が推定可能かを示す必要がある。そこで、本章では、提案手法の有用性を示すにあたり、エージェントによるゲームプレイのログからログの類型化の要因となり得る行動を推定できるかを確かめる。

5.2 実験計画

本節では、エージェントにプレイさせたゲームのログからログの類型化の要因となり得るエージェントの行動の推定可能性を確かめる実験について述べる。以下、実験で使用するゲームおよびエージェントのモデル、計算機環境、実験手順、分析方法、結果、考察の順に説明する。最後に、本実験をまとめる。

5.2.1 ゲームおよびエージェントのモデル

本実験では、3.3.4 節で説明したシンライフキャリアゲーム バージョン 2 とエージェントを使用し、そのログを分析の対象とする。

5.2.2 計算機環境

本実験で使用するゲーミングの使用環境は、第4章に準ずる。

5.2.3 実験手順

本実験ではシンライフキャリアゲーム バージョン2を使い、ゲームを実行してログを収集し、ログを類型化し、ログの類型化の要因となり得るエージェントの行動を推定する（図5.1）。本実験では、ユニークな乱数シードを用いてゲームを10000回実行した。各ゲームでは、1体のエージェントがエージェントとしてゲームに参加した1ゲームあたり10ラウンドずつ実施された。全てのゲームが終了した時点で、全部でエージェント10000体分のログを回収した。その後、ログを類型化し、さらにログの類型化の要因を推定した。




図 5.1: 実験と分析の手順

5.2.4 分析方法

この節では、本研究で用いた分析法について解説する。本実験で扱うゲームにおけるエージェントの意思決定履歴は、シンボリックなデータである。そこで、本研究では、ゲームのログに含まれるエージェントの行動の履歴情報を文字列コードに変換する。文字列コードには、ラウンドごとにエージェントがとった行動が刻まれている。この文字列コードには、エージェントの行動とその行動がとられたラウンドによって階層構造を備えているとみなせるため、ログの類型化に階層型クラスタリング法を使用して類型化する。文字列コード同士を比較するため、レーベンシュタイン距離 [72] を用いてログ間の類似性を比較することとする。ここで使用する距離関数はワード法とする。クラスタ内のデータ間の類似性の高さを重視するワード法を用いることで、この次に行うログの類型（クラスタ）間の比較の際に、クラスタ別の文字列コードの差異が現れ易くする。最後に、ログの類型化の要因となり得るエージェントの行動を推定するために、決定木を構築する [73][74]。決定木分析は、データを学習したモデルがツリー形式で出力されるため、モデルが学習したルールを解釈し易く、分析対象のデータから知識を抽出する手法として有用である。今回採用した決定木構築手法は、最も典型的な手法の一つとされる C4.5 を採用する。以降、各手法について詳細を説明する。

階層的クラスタリング

階層的クラスタリング (Hierarchical clustering) とは、類似度の高いサンプルの組み合わせから優先的にまとめていく手法である [75]。階層的クラスタリングは、一般的に、凝集型 (agglomerative) と分岐型 (divisive) の二種類に分類される [76]。凝集型では、各データは単独のクラスタで開始し、階層の上に移動するに連れてデータをマージしていく。分岐型はトップダウンなアプローチであり、すべてのデータが1つのクラスタで開始され、分割が階層を下って行くに連れて再帰的に分割が実行される。分岐型では、1個のサンプルで構成される N 個のクラスタがある初期状態から、クラスタ間の距離に基づき、最も距離が近い一組のクラスタを逐次的に併合するという手続きを取る。

この手続を、すべてのサンプルが一つのクラスタに併合されるまで繰り返すことで、最終的に階層構造（デンドログラムで表現される）を獲得する。クラスタ C_1 とクラスタ C_2 の距離関数 $D(C_1, C_2)$ の違いにより、複数手法に分かれる。各手法について以下に記す。

最短距離法 (nearest neighbor method) または単純連結法 (single linkage method)

$$D(C_1, C_2) = \min_{x_1 \in C_1, x_2 \in C_2} D(x_1, x_2) \quad (5.1)$$

最長距離法 (furthest neighbor method) または完全連結法 (complete linkage method)

$$D(C_1, C_2) = \max_{x_1 \in C_1, x_2 \in C_2} D(x_1, x_2) \quad (5.2)$$

群平均法 (group average method)

$$D(C_1, C_2) = \frac{1}{n_1 n_2} \sum_{x_1 \in C_1} \sum_{x_2 \in C_2} D(x_1, x_2) \quad (5.3)$$

ウォード法 (Ward's method)

$$D(C_1, C_2) = E(C_1 \cup C_2) - E(C_1) - E(C_2) \quad (5.4)$$

ただし,

$$E(C_1) = \sum_{x_1 \in C_1} (D(x, c_i))^2$$

ここで, c_i は C_i の重心であり,

$$c_i = \sum_{x \in C_i} x / |C_i|$$

ウォード法は, 各サンプルから, そのサンプルを含むクラスタのセントロイドまでの距離の二乗の総和を最小化するという処理を行う. 本研究では, ウォード法を採用する.

距離関数

我々は, 前節で解説した階層的クラスタリングを用いて, ゲーミングで得られた時系列データを解析する. 時系列解析に用いられる全ての手法では, データ間の類似性を, 距離を求めて比較する手続きが含まれている [77]. 距離関数は, データ間の距離を推定するために用いられる. 一般的に, データ間の類似性を評価する際には, ユークリッド距離 (Euclidean distance) を利用するのが典型的である. しかし, ユークリッ

ド距離は時系列データの分析には適さない。時系列データの比較に適した距離としては、Compression-based Dissimilarity Measure (CDM) [78], レーベンシュタイン距離 (Levenshtein distance) [72], Longest Common Sub-Sequence (LCSS) [79], Dynamic Time Warp (DTM) [80] などが挙げられる。

レーベンシュタイン距離

レーベンシュタイン距離とは、一組の文字列がどの程度類似しているかを示す距離の一種である。レーベンシュタイン距離は、「一文字の挿入・削除・置換によって、一方の文字列をもう一方の文字列に変形するのに必要な手順の最少回数」と定義される。レーベンシュタイン距離は式 (5.5) で定義される。

$$lev_{a,b}(i, j) = \begin{cases} \max(i, j) \\ \min \begin{cases} lev_{a,b}(i-1, j) + 1 \\ lev_{a,b}(i, j-1) + 1 \\ lev_{a,b}(i-1, j-1) + 1 \end{cases} \end{cases} \quad (5.5)$$

レーベンシュタイン距離は、動的計画法を用いて求められるのが一般的である。文字の挿入・削除・置換という3つの操作の内のいずれかを1回実行する際のコストを1とし、文字列を変換し終わるまでにかかるコストの合計を求め、最もコストが小さい方法を動的計画法に基づいたアルゴリズムで求めた結果が、レーベンシュタイン距離となる。

C4.5 アルゴリズム

C4.5[73][74] は、Quinlan によって1993年に提案された決定木を生成するアルゴリズムである。決定木は、意思決定とその結果をツリー状にモデル化したもので、意思決定支援ツールの一つである。C4.5によって生成された決定木は分類問題に使用することができる。

決定木では分岐の基準をどのように決定するかが重要な論点となる。C4.5では情報量（エントロピー）を用いて木を分岐させる条件を決定する。あるデータ集合の状態 X に関するあいまいさは以下の式で定義されるエントロピー $\text{Info}(X)$ で測定することが

できる．ある値で木を分岐させたとき，分岐前の状態を X_0 ，分岐後の状態を X_1 とすると，Gain（相互情報量）は (5.7) で計算され，Gain の値が最も大きくなるように分割される．この処理を再帰的に繰り返すことで決定木を得る．

$$Info(X) = - \sum_{j=1}^k p(j|t) \log_k p(j|t) \quad (5.6)$$

$$Gain = Info(X_0) - Info(X_1) \quad (5.7)$$

5.2.5 結果

ゲームを実施した結果，10000 個のログが回収され，それらのログから 41 種類のコードを抽出した．提案手法の評価を試みるにあたり，ログは単純に 2 つ乃至 3 つのログの種類（シナリオ）に分類された（図 5.2 と図 5.3）．ログを 2 つのシナリオに分類した際に，片方のシナリオを S21，もう片方のシナリオを S22 と名付けた．さらに，S22 は S221 と S222 に分かれた．S21 と S22 を構成するログの数は，それぞれ 4929 個（49.29%）と 5071 個（50.71%）であった．また，S221 と S222 を構成するログの数は，それぞれ 2696 個（26.96%），2375 個（23.75%）であった．また，S221 と S222 それぞれに属するログにおける，ラウンド 6 までの時間資源の配分量の累積値の分布を表したグラフを図 5.4 に載せる．

決定木を用いたログの類型化の要因となりうるエージェントの行動の分析結果を報告する．決定木を用いた交差検証の結果を図 5.5 にまとめた．Precision は，正として分類されたデータの総量に対する，正として正しく分類されたデータの比率である．Recall は，正のデータの総量に対する，正として正しく分類されたデータの比率である．F1 とは Recall と Precision の調和平均である．Accuracy は，分類されたデータの総量に対する正しく分類されたデータの割合である．これらの値は，scikit-learn[81] を用いて算出された．加えて，分析で明らかになったログの類型化（シナリオの分岐）の要因となり得るエージェントの行動をまとめた（図 5.6 と図 5.7）．S21 と S22 の間のログの類型化の要因となり得るエージェントの行動は「ラウンド 5 で GP が選択されるかされないか」または「ラウンド 5 で BP が選択されるかされないか」であった（全ての交差検証で，正解率は 99% を超えている）．これらは，一見すると異なる分岐条件であるように見えるが，エージェントがラウンド 5 で選択した行動は，GP か BP のどちらかしかないため，実質的には両者は同じである．

S21												S22											
No.	ROUND										Frequency	No.	ROUND										Frequency
	1	2	3	4	5	6	7	8	9	10			1	2	3	4	5	6	7	8	9	10	
1	GP	GP	GP	GP	GP	IP	IP	IP	IP	IP	1664	1	BP	BP	BP	BP	BP	BP	IP	IP	IP	IP	1681
2	GP	GP	GP	GP	GP	GP	IP	IP	IP	IP	1585	2	BP	BP	BP	BP	BP	IP	IP	IP	IP	IP	736
3	IP	GP	GP	GP	GP	GP	GP	IP	IP	IP	542	3	BP	BP	BP	BP	BP	BP	IP	IP	IP	IP	564
4	IP	GP	GP	GP	GP	GP	IP	IP	IP	IP	539	4	IP	BP	BP	BP	BP	BP	BP	IP	IP	IP	542
5	IP	IP	GP	GP	GP	GP	GP	IP	IP	IP	179	5	BP	BP	BP	BP	BP	BP	BP	BP	IP	IP	368
6	IP	IP	GP	GP	GP	GP	GP	GP	IP	IP	165	6	IP	BP	BP	BP	BP	BP	IP	IP	IP	IP	279
7	IP	IP	IP	GP	GP	GP	GP	GP	IP	IP	54	7	IP	IP	BP	BP	BP	BP	BP	BP	IP	IP	190
8	GP	GP	GP	GP	GP	GP	IP	IP	IP	IP	52	8	IP	BP	BP	BP	BP	BP	BP	BP	IP	IP	181
9	IP	IP	IP	GP	GP	GP	GP	GP	GP	IP	49	9	IP	BP	BP	BP	BP	BP	BP	BP	BP	IP	111
10	IP	IP	IP	IP	GP	GP	GP	GP	GP	GP	29	10	IP	IP	BP	BP	BP	BP	BP	IP	IP	IP	78
11	IP	IP	IP	IP	GP	GP	GP	GP	GP	IP	24	11	IP	IP	IP	BP	BP	BP	BP	BP	BP	IP	65
12	IP	GP	GP	GP	GP	GP	GP	GP	IP	IP	22	12	IP	IP	BP	BP	BP	BP	BP	BP	BP	IP	57
13	IP	IP	IP	IP	IP	GP	GP	GP	GP	GP	14	13	BP	BP	BP	BP	BP	BP	BP	BP	BP	IP	41
14	IP	IP	IP	IP	IP	IP	GP	GP	GP	GP	4	14	IP	IP	IP	BP	BP	BP	BP	BP	BP	BP	40
15	IP	IP	IP	IP	GP	GP	GP	GP	GP	GP	3	15	IP	IP	BP	BP	BP	BP	BP	BP	BP	BP	37
16	IP	IP	IP	IP	IP	IP	IP	GP	GP	GP	2	16	IP	IP	IP	IP	BP	BP	BP	BP	BP	BP	32
17	IP	IP	IP	IP	IP	IP	IP	IP	GP	GP	1	17	IP	IP	IP	BP	BP	BP	BP	BP	IP	IP	19
18	IP	IP	GP	GP	GP	GP	GP	GP	GP	IP	1	18	IP	BP	BP	BP	BP	BP	BP	BP	BP	BP	17
												19	IP	IP	IP	IP	IP	BP	BP	BP	BP	BP	15
												20	IP	IP	IP	IP	BP	BP	BP	BP	BP	IP	7
												21	BP	BP	BP	BP	BP	BP	BP	BP	BP	BP	6
												22	IP	IP	IP	IP	IP	IP	BP	BP	BP	BP	4
												23	IP	IP	IP	IP	IP	IP	IP	BP	BP		1

図 5.2: ログの類型化の結果 (類型数: 2)

S21												S222											
No.	Round										Frequency	No.	Round										Frequency
	1	2	3	4	5	6	7	8	9	10			1	2	3	4	5	6	7	8	9	10	
1	GP	GP	GP	GP	GP	IP	IP	IP	IP	IP	1664	1	BP	BP	BP	BP	BP	BP	BP	IP	IP	IP	564
2	GP	GP	GP	GP	GP	GP	IP	IP	IP	IP	1585	2	IP	BP	BP	BP	BP	BP	BP	IP	IP	IP	542
3	IP	GP	GP	GP	GP	GP	GP	IP	IP	IP	542	3	BP	BP	BP	BP	BP	BP	BP	BP	IP	IP	368
4	IP	GP	GP	GP	GP	GP	IP	IP	IP	IP	539	4	IP	IP	BP	BP	BP	BP	BP	BP	IP	IP	190
5	IP	IP	GP	GP	GP	GP	GP	IP	IP	IP	179	5	IP	BP	BP	BP	BP	BP	BP	BP	IP	IP	181
6	IP	IP	GP	GP	GP	GP	GP	GP	IP	IP	165	6	IP	BP	BP	BP	BP	BP	BP	BP	BP	IP	111
7	IP	IP	IP	GP	GP	GP	GP	GP	IP	IP	54	7	IP	IP	BP	BP	BP	BP	BP	IP	IP	IP	78
8	GP	GP	GP	GP	GP	GP	IP	IP	IP	IP	52	8	IP	IP	IP	BP	BP	BP	BP	BP	BP	IP	65
9	IP	IP	IP	GP	GP	GP	GP	GP	GP	IP	49	9	IP	IP	BP	BP	BP	BP	BP	BP	BP	IP	57
10	IP	IP	IP	IP	GP	GP	GP	GP	GP	GP	29	10	BP	BP	BP	BP	BP	BP	BP	BP	BP	IP	41
11	IP	IP	IP	IP	GP	GP	GP	GP	GP	IP	24	11	IP	IP	IP	BP	BP	BP	BP	BP	BP	BP	40
12	IP	GP	GP	GP	GP	GP	GP	GP	IP	IP	22	12	IP	IP	BP	BP	BP	BP	BP	BP	BP	BP	37
13	IP	IP	IP	IP	IP	GP	GP	GP	GP	GP	14	13	IP	IP	IP	IP	BP	BP	BP	BP	BP	BP	32
14	IP	IP	IP	IP	IP	IP	GP	GP	GP	GP	4	14	IP	IP	IP	BP	BP	BP	BP	BP	BP	IP	19
15	IP	IP	IP	IP	GP	GP	GP	GP	GP	GP	3	15	IP	BP	BP	BP	BP	BP	BP	BP	BP	BP	17
16	IP	IP	IP	IP	IP	IP	IP	GP	GP	GP	2	16	IP	IP	IP	IP	IP	BP	BP	BP	BP	BP	15
17	IP	IP	IP	IP	IP	IP	IP	IP	GP	GP	1	17	IP	IP	IP	IP	BP	BP	BP	BP	BP	IP	7
18	IP	IP	GP	GP	GP	GP	GP	GP	GP	IP	1	18	BP	BP	BP	BP	BP	BP	BP	BP	BP	BP	6
												19	IP	IP	IP	IP	IP	IP	BP	BP	BP	BP	4
												20	IP	IP	IP	IP	IP	IP	IP	BP	BP		1
S221																							
No.	Round										Frequency												
	1	2	3	4	5	6	7	8	9	10													
1	BP	BP	BP	BP	BP	BP	BP	IP	IP	IP	1681												
2	BP	BP	BP	BP	BP	IP	IP	IP	IP	IP	736												
3	IP	BP	BP	BP	BP	BP	IP	IP	IP	IP	279												

図 5.3: ログの類型化の結果 (類型数: 3)




図 5.4: 全シナリオ間での余暇に費やされた時間資源の累積値の比較

C.V.	Scenario	Total	Proportion (%)	Precision (%)	Recall (%)	F1 (%)	Accuracy (%)
#1	1	1242	49.68	100.0	99.36	99.68	99.68
	2	1258	50.32	99.37	100.0	99.68	
#2	1	1199	47.96	99.42	100.0	99.71	99.72
	2	1301	52.04	100.0	99.46	99.73	
#3	1	1253	50.12	99.52	100.0	99.76	99.76
	2	1247	49.88	100.0	99.52	99.76	
#4	1	1235	49.40	99.68	100.0	99.84	99.84
	2	1265	51.60	100.0	99.68	99.84	

シナリオ数: 2個

C.V.	Scenario	Total	Proportion (%)	Precision (%)	Recall (%)	F1 (%)	Accuracy (%)
#1	1	1242	49.68	100.0	99.36	99.68	99.68
	2	661	26.44	98.80	100.0	99.40	
	3	597	23.88	100.0	100.0	100.0	
#2	1	1199	47.96	99.42	100.0	99.71	99.96
	2	710	28.40	100.0	100.00	100.0	
	3	591	23.64	100.0	98.82	99.40	
#3	1	1253	50.12	99.52	100.0	99.76	99.76
	2	649	25.96	100.0	100.0	100.0	
	3	598	23.92	100.0	99.00	99.50	
#4	1	1235	49.40	99.68	100.0	99.84	99.84
	2	676	27.04	100.0	100.0	100.0	
	3	589	23.56	100.0	99.32	99.66	

シナリオ数: 3個

図 5.5: 決定木による分析のクロスバリデーション結果

また、S221 と S222 の間のログの類型化の要因となり得るエージェントの行動は「ラウンド7でBPが選択されるかされないか」または「ラウンド7でIPが選択されるかされないか」であることがわかった（全ての交差検証で、正解率は99%を超えている）。これらは一見すると異なる要因に見えるが、エージェントがラウンド7で選択した行動は、BP か IP のどちらかしかないため、実質的には両者は同じである。

S21											Frequency
No.	ROUND										
	1	2	3	4	5	6	7	8	9	10	
1	GP	GP	GP	GP	GP	IP	IP	IP	IP	IP	1664
2	GP	GP	GP	GP	GP	GP	IP	IP	IP	IP	1585
3	IP	GP	GP	GP	GP	GP	GP	IP	IP	IP	542
4	IP	GP	GP	GP	GP	GP	IP	IP	IP	IP	539
5	IP	IP	GP	GP	GP	GP	GP	IP	IP	IP	179

S22											Frequency
No.	ROUND										
	1	2	3	4	5	6	7	8	9	10	
1	BP	BP	BP	BP	BP	BP	IP	IP	IP	IP	1681
2	BP	BP	BP	BP	BP	IP	IP	IP	IP	IP	736
3	BP	BP	BP	BP	BP	BP	BP	IP	IP	IP	564
4	IP	BP	BP	BP	BP	BP	BP	IP	IP	IP	542
5	BP	BP	BP	BP	BP	BP	BP	BP	BP	IP	368

獲得したルール

- シナリオS21: 5ラウンド目でGPを選択すること
 - “GP(労働重視型)”を選択し、後に“IP(余暇重視型)”へ方針変更
- シナリオS22: 5ラウンド目BPを選択すること
 - “BP(バランス型)”を選択し、後に“IP(余暇重視型)”へ方針変更

図 5.6: 決定木によって得られたルール（類型数：2）

S221											Frequency
No.	Round										
	1	2	3	4	5	6	7	8	9	10	
1	BP	BP	BP	BP	BP	BP	BP	IP	IP	IP	1681
2	BP	BP	BP	BP	BP	BP	IP	IP	IP	IP	736
3	IP	BP	BP	BP	BP	BP	BP	IP	IP	IP	279

S222											Frequency
No.	Round										
	1	2	3	4	5	6	7	8	9	10	
1	BP	BP	BP	BP	BP	BP	BP	BP	IP	IP	564
2	IP	BP	BP	BP	BP	BP	BP	BP	IP	IP	542
3	BP	BP	BP	BP	BP	BP	BP	BP	BP	IP	368
4	IP	IP	BP	BP	BP	BP	BP	BP	BP	IP	190
5	IP	BP	BP	BP	BP	BP	BP	BP	BP	IP	181

獲得したルール

- シナリオS221: 7ラウンド目でIPを選択すること
 - 余暇に時間を割かず早い段階で健康が悪化したため、早めに“IP(余暇重視型)”へ方針転換
- シナリオS222: 7ラウンド目でBPを選択すること
 - 余暇に時間を割いていたため健康が悪化し難く、遅めに“IP(余暇重視型)”へ方針転換

図 5.7: 決定木によって得られたルール（類型数：3）

5.2.6 考察

ゲーミングで回収したログを分析し、S21 と S22 の間のログの類型化の要因となり得るエージェントの行動と、S221 と S222 の間のログの類型化の要因となり得るエージェントの行動を明らかにした。どのエージェントの行動も、正解率は極めて高いことが確認された。以下、実験結果を考察する。

まず、S21 と S22 間のシナリオの性質の違いを考察する。S21 と S22 を構成するログの文字列コードを比較すると、S21 に属する文字列コードは GP と IP で構成されていた。一方、S22 に属するログの文字列コードは BP と IP で構成されていた。従って、S21 を構成するログに対応するエージェントは、正規雇用労働へ従事してお金資源を増やそうとしたと見える。その一方で、S22 を構成するログに対応するエージェントは、労働・学習・余暇に満遍なく取り組んで、各種資源を増やそうとしたと見える。

ログが S21 と S22 に分かれた要因は「ラウンド5で GP を選択するかしないか」か「ラウンド5で BP を選択するかしないか」であった。これらは、一見すると異なるエージェントの行動に見えるが、実質的には同じ条件といえる。なぜなら、全てのコードを確認すると、エージェントがラウンド5で選択した行動は、GP か BP のどちらかしかないためである。S21 に属する文字列コードは、ラウンド5までは主に GP が選択され、ラウンド6以降に GP に代わって IP に行動が切り変わっている (98.92%)。一方、S22 に属するログの文字列コードは、ラウンド6以降に BP に代わって IP に行動が切り変わっている (97.00%)。これらの文字列コードの特徴的な違いと、決定木分析によって推定されたログの類型化の要因となりえるエージェントの行動は、互いに整合的である。

次に、S221 と S222 の間のログの種類の性質の違いを考察する。S221 と S222 に属するログの文字列コードは、いずれも BP と IP で構成されていた。どちらのログの種類も、エージェントの意思決定プロセスは似通っている。S221 と S222 の間のログの違いは、エージェントが BP から IP に行動を切り替えるタイミングである。S221 に属するログに対応する文字列コードでは、遅くともラウンド7までに BP から IP に行動が切り替わっている (100.0%)。一方、S222 に属するログに対応する文字列コードでは、ラウンド8以降に BP から IP へ行動が切り替わっている (99.96%)。ここで、S221 と S222 の間で、ラウンド6までにエージェントが LS に割り当てた時間資源の累積量の値を比較すると、S221 の方が S222 より多く見えた (図5.4)。そこで、ウィルコクソンの順位和検定を用いて両シナリオ間で当該の値が異なるかを検討したところ、有意な

差があった ($p = 2.4e-147$, $DS = 0.65$). つまり, S221 に属するログに対応するエージェントの方が, S222 に属するログに対応するエージェントよりも, 余暇に時間を割かず, お金儲けや能力開発を優先した結果, 前者の方が比較的早いタイミングで行動が切り替わった可能性がある. この仮説の確からしさは, 決定木分析によって明らかとなったログの類型化の要因となり得るエージェントの行動 (ラウンド7までにBPからIPに行動を切り替えたエージェントに対応するログはS221に分類され, ラウンド8以降に行動を切り替えたエージェントに対応するログはS222に分類される.) によって支持された.

以上から, 我々が提案した手法をゲーミング結果の分析に用いることで, ログの類型を抽出してそれらの性質を明らかにし, さらに, エージェントが, いつ, どのような意思決定をしたために, ログが類型化した可能性があるかを説明するエージェントの行動を推定できることを示した. デブリーフィングでは, ゲームにおける特徴的なプロセスとそれを導く決定的な判断を明らかにすることが重要である. 本実験では, これらに相当する知識を得ることができた. ゲーミングを利用するファシリテータが本手法を利用することで, デブリーフィングにおけるファシリテータによる What-If 分析のための前提知識の共通化の道筋が立った.

また, 本実験で明らかとなったログの類型化の要因となりうるエージェントの行動の他にも, 新たに要因が見つかる可能性は十分にある. 本実験ではログの種類の数を3つまでとしているが, クラスタ数を更に増やしていくことで, 新たなログの類型化の要因となりうるエージェントの行動が見つかる可能性がある.

5.3 まとめ

本章では, 本研究の提案手法の有効性を確かめるにあたり, エージェントが参加したゲームプレイのログから P-GL-AA を明らかにできるかを確かめた. そのため, エージェントにゲームをプレイさせて回収したログを階層型クラスタリングで類型化し, 決定木 (C4.5) を用いてログの類型化の要因となり得るエージェントの行動の推定を試みた. 実験の結果, ログの類型化の要因となり得るエージェントの行動の推定に成功した.

第6章 結論

6.1 本研究の結論

本研究では、ファシリテータがゲーミングを実施する前の段階でエージェントにゲームをプレイさせて得たログからの P-GL-AA (Patterns of Gaming Logs and Actions of Agents) の抽出手法を提案した。提案手法の有用性を確かめるために、エージェントによるゲームプレイのログからログの類型が抽出であるかと、同様のログからログの類型化に影響を及ぼし得るエージェントの行動が推定できるかについて、実験的に確かめることとした。従来研究と本研究の関係を整理した結果、提案手法を使用して得られる P-GL-AA をファシリテーター同士で共有することで、どんなファシリテーターでもゲームで起こり得るシナリオとそのシナリオの生成要因であるエージェントの行動について共通認識を持った上で、デブリーフィングでの What-If 分析のファシリテーションに取り組むことが期待できることがわかった。その上で、本研究の提案手法である「P-GL-AA をエージェントがプレイしたゲームのログから抽出する手法」について説明し、さらに想定される提案手法の使用者および提案手法が適用されるゲームの要件を解説した。最後に、第4章と第5章の実験では、エージェントがプレイしたゲームのログを分析することで、ログの類型が抽出可能であることと、ログの類型化に影響を与えた可能性のある行動がいつ・どのようなものであったかを明らかにできることを示した。

本研究ではログの類型化手法として DEA (第4章) と機械学習によるクラスタリング (第5章) を採用しているが、これらはログのサンプルサイズの規模の違いによって使い分ける必要がある。DEA はログ (DMU) のどの入力変数および出力変数を評価対象として選択するかで、分析対象のログの最少数が経験則で定められているものの [60], これを満たした上で大きすぎないサンプルサイズのログを対象としたログの類型化への DEA の適用に留まることが望ましい。現時点では、大量のログを対象とした分析には DEA の使用は不向きな場合がある。というのも、近年はビッグデータに対する

DEA の適用が模索されているものの、DMU の数が大規模になると線形計画法 (LP) 問題の計算にかかる時間が指数関数的に増大するためである [82]。一方、本章で述べたように、ログを分析してログの類型を生成し得るエージェントの行動の要因を推定するには、大量のログが必要である。従って、ログの類型化の抽出とその生成要因の推定という用途には、機械学習によるクラスタリングを適用するのが望ましい。

本研究の提案手法が対象とするゲームは、エージェントシミュレーションで同型のモデルを扱うことが可能で、かつ、1 人のプレイヤーがゲームのシステムと相互作用する環境が整っている必要がある。従って、複数のプレイヤーが参加して互いに相互作用することが求められるゲームには、提案手法を適用することはできない。このことに関しては、将来の課題としたい。

本研究の提案手法で明らかとなった P-GL-AA をファシリテータに与えることで、ファシリテータはシナリオの検討の前提知識を共有する事ができるようになる。しかしながら、デブリーフィングでの What-If 分析にけるファシリテーションの個人差が縮まる可能性については未知数である。よって、将来的には、ファシリテータによる P-GL-AA の把握の有無がファシリテーションの個人差の大きさに影響を与えるかについて確かめるつもりである。

6.2 本研究の貢献

近年、ゲーミングは「参加型のアプローチ」の具体的な手法と見做されるようになった [52][29]。参加型のアプローチとは、ステークホルダとなり得る人間の参加によってシステムの動きと参加者の行動の双方について知見を得るだけでなく、それらについての参加者による理解を促進させる活動のことである。参加型のアプローチの研究事例としては、中野による現実のビジネスケースとゲーミングの融合を試みた研究 [83] や、越山によるゲーミングに参加するプレイヤーの認知・判断の内容の測定・評価についての研究 [84] がある。

本研究もまた「参加型アプローチ」に位置づけられる研究事例のひとつである。本研究の提案手法を用いたシナリオ分析によって、分析対象のゲーミングでどのようなシナリオがあり得るのか、複数のシナリオが存在する場合は、ゲームプレイにおけるエージェントのどのような行動の違いがシナリオの違いとして現れるのかが明らかとなる。

本研究には四つの発展が考えられる (図 6.1)。

- シナリオの分岐に関わるプレイヤ（人間）による問題の構造の理解の分析
- ビジネスケースと共通の文脈で起こり得たシナリオの分析
- 自己学習による人的資本形成をテーマとしたゲーミングの開発及び自己学習による人的資本形成にかかるシナリオの分析
- 分析者の分析関心に基づいたシナリオ分析

第一に「シナリオの分岐に関わるプレイヤ（人間）による問題の構造の理解の分析」を挙げる。本研究では、エージェントの意思決定の履歴情報を分析対象としたが、エージェントがどのような情報処理のプロセスを経て意思決定した結果、シナリオが分岐したかを明らかにすることもまた有益である。この問題は、本研究と越山の研究 [85] と組み合わせることで解決することができる。越山はゲームプレイにおけるプレイヤ（人間）にパフォーマンスシートと呼ばれるアンケート用紙を与え、ゲームプレイのラウンド毎に自らの意思決定の結果とその時点における問題の構造について回答させた。このような情報で構成されたログを分析することで、プレイヤの意思決定の背後にある問題構造の理解の変化を知ることができる。越山が開発したパフォーマンスシートに相当する機能をゲーミングシステムに実装することで、上記の問題は解決できる。

また、この研究はケースやエージェントシミュレーションの領域にも応用できる。例えば、エージェント内部の情報処理の特徴的なプロセスとゲーミングのシナリオの分岐の関係を形式的に記述して仮想ケースを作成することで、仮想ケース同士の比較や、仮想ケースと現実のケースを比較する事ができるようになる。エージェントシミュレーションではこれに類する試みが既に行われている。菊地らは、エージェントシミュレーションのログの分析結果を MDDM と呼ばれる形式的記述ツール [86] を用いて仮想ケースを作成し、現実のケースとの比較するという試みを行っている [87]。また、当該仮想ケースを元にして当該ゲーミングと同型のエージェントシミュレーションのモデルの設計・開発や、その設計仕様に変更を加えることも可能である。

第二に「ビジネスケースと共通の文脈で起こり得たシナリオの分析」を挙げる。本研究と中野の研究 [88] の組み合わせである。中野は現実のビジネスを元に作成されたビジネスケースを元にビジネスゲームを開発した。実在する企業の経営者が経験したビジネスの成功モデルを参考にして開発されたゲーミングは、リアリティという点で学びが多い。しかし、もしも同じ経営者が当時と全く同じ状況に再び直面したとして、当該ビジネスケースの内容と同じ軌跡を辿るという保証はどこにもない。全く同じ経営

方針で状況に臨んだとしても、もしかしたら違う結果となるかもしれない。中野のビジネスケースで得たログを本研究の提案手法を用いてシナリオ分析にかけると、現実のビジネスでは観測されなかった別の展開を示唆するシナリオを見つけることができる。もし新たなシナリオが発見されたときは、前述した通りの方法で仮想ケースを作成することができる。そして、当該ビジネスケースと当該仮想ケースを比較することができる。この研究はMBAにおけるケーススタディやケースメソッドといった教育アプローチと接地する余地がある。また、先述の通り、仮想ケースをもとに、ゲーミングと同型のモデルのエージェントシミュレーションのモデルを設計・開発したり、その設計仕様に修正を加えることができる。

第三に「分析者の分析関心に基づいたシナリオ分析」を挙げる。本研究と後藤の研究[89]の組合せである。後藤はゲームプレイで得たログの分類を分析者の分析上の関心の構造に基づいて分類するという手法を開発した。仮に同じゲームを用いたゲーミングで得たログを分析対象にし、異なる観点に立ってログを類型化すれば、結果的に抽出されるシナリオの性質もまた他の類型化手法によって得たシナリオと性質が異なり、シナリオを分岐させる要因もまたユニークなものになると予想される。後藤が開発した類型化手法に限らず、様々な類型化手法を試すことで、得られる知識の特性も変わると期待される。この研究もまた、これまでの応用案と同様に、ケースとエージェントシミュレーションへの接地を見込むことができる。

第四に「自己学習に寄る人的資本形成をテーマとしたゲーミングの開発及び自己学習による人的資本形成にかかるシナリオの分析」を挙げる。本研究と奥村の研究[90]の組み合わせ案を説明する。奥村は、現代日本社会における社会人の自己学習と人的資本形成の関係を調査した。調査の結果、自己学習によって人的資本形成が進む証拠を得た。もしも自己学習による人的資本形成をテーマにしたゲーミングを開発し、そのゲームを実際の人間の意思決定を模倣したモデルを備えたエージェントに同ゲーミングをプレイさせ、そこで得たログを提案手法を用いてシナリオ分析にかけることができたら、どのような自己学習の戦略を採用すると人的資本形成に寄与するのか（あるいは寄与しないのか）の仮説を得ることができる。また、シナリオ分析で得た知識を形式記述言語で仮想ケース化することで、ケース教材として活用することもできる。また、同ゲーミングのモデルと同型のエージェントシミュレーションのモデルを設計し、シミュレーション結果を感度分析にかけると、ゲーミング結果のシナリオ分析で得た仮説の確からしさを補強するような結果を得ることができる。

ゲーミングの研究			応用・ 接地	隣接領域における本研究の応用研究	
研究(組合せ対象)		本研究 (組合せ元)		ケース	エージェント・シミュレ- ーション
文献	研究の内容				
越山2011	プレイヤーの問題の構造の理解 の計測手法の開発	シナリオを分岐させた行 動を促した問題の構造の 理解の分析	→	①問題構造の理解を踏まえた 仮想ケースの作成②既存の ケースとの接地	問題構造の理解を踏まえた仮想 ケースに基づいたエージェント・ モデルの設計
中野2007	ビジネスケースを元にしたビ ジネスゲームの開発	同ビジネスケースと共通 の文脈で起こり得たシナリ オの分析		①同ビジネスケースと共通の 文脈の下でのオルタナティブの 仮想ケースの作成 ②既存のケースとの接地	同ビジネスケースを元に設計さ れたエージェント・モデルによる シミュレーション結果と仮想ケー スの比較
奥村2021	人的資本形成と自己学習の 関係の調査	①自己学習による人的資本 形成をテーマにした ゲーミングの開発②自己 学習による人的資本形成 に係るシナリオの分析		①自己学習による人的資本形 成をもたらす仮想ケースの作 成」②既存ケースとの接地	自己学習による人的資本形成を テーマにしたエージェント・モデ ルの設計。
後藤2020	分析関心に基づいた社会シ ミュ・ログの階層的分類と可 視化手法の開発	分析者の分析関心に基づ いたシナリオ分析		①分析者の分析関心に基づい た仮想ケースの作成 ②既存のケースとの接地	分析者の分析関心に基づいた 仮想ケースをもとにしたエーजे ント・モデルの設計

図 6.1: 本研究の学問的貢献

6.3 今後の展望

本研究の今後の課題として、提案手法の発展を、発展の方向性として以下の2点を挙げる。

- シナリオ分析で獲得する知識の多様化
- デブリーフィングの省力化

本研究で提案した分析手法を利用する際に、分析で使用する技法を変えることで、分析者は様々な特徴を備えた知識を獲得できる。ログの類型化をする際に具体的な類型化手法を入れ替えることで、分析者は様々な類型を獲得することができる。本研究では類型化手法としてDEAと階層型クラスタリングを使用したのが、当然ながら適用可能な類型化手法はこれらに限らない。

ファシリテータがP-GL-AAを把握することで、将来的にはデブリーフィングにおけるファシリテーションの個人差を縮めることに貢献できる。ゲーミングを用いた教育では、学習効果を高める上でデブリーフィングが最も重要な要素であると考えられているが[6]、その一方でファシリテーションには個人差があることも指摘されており[7][14][15]、ファシリテータ次第でその内容や効果に違いがある可能性がある。これに関して、提案手法を用いてP-GL-AAを明らかにし、ファシリテータに把握させることで、ファシリテータの間でファシリテーションの前提知識であるシナリオとその生成要因であるプレイヤーの行動に関して共通の認識を持たせられる。ファシリテータ同士

でゲームのシナリオとその生成要因に関する共通認識を揃えた上で、デブリーフィングで What-If 分析を実行してシナリオの検討を行うことで、What-If 分析でのファシリテーションの内容や効果の個人差を縮めることができる。

謝辞

東京工業大学・名誉教授の寺野隆雄先生には、研究テーマの絞り込み、論文作成、学会発表など、研究生生活の重要な場面において、ご指導を賜りました。寺野隆雄先生から頂いた的確なアドバイスのお陰で、安定した研究生生活を送ることができました。

東京工業大学大学院・教授の山村雅幸先生には、旧寺野研究室が閉鎖されてから長期に渡って大変お世話になりました。研究の進捗がなかなか出ない中、ただただ辛抱強く見守って頂きました。山村先生から時折頂ける率直な励ましのお言葉が、不安と心細さだけが募る博士生活の中で大いに励みになっていました。

関東学院大学理工学情報ネット・メディアコース・教授の吉川厚先生には、長い大学院生活において研究の内容について議論を深めることに大いに協力して頂きました。吉川先生と議論を繰り返す中で、研究に対する向き合い方が徐々に形づくられていったように思います。

東京工業大学大学院・特別研究員である國上真章さんには、2015年に博士後期課程に入学してから本年に至るまで、汎ゆる面で私の研究にとっても辛抱強く付き合ってくださいました。毎週のゼミでの議論を通じて、多数の有益な助言を頂き、研究を導いて下さいました。

2009年の東京工業大学大学院入学以来、修士修了から博士課程入学までの間も含め、14年間に渡って、東京工業大学大学院・旧寺野研究室のメンバー各位には大変お世話になりました。様々なバックボーンを持つ皆様と、研究や日々の仕事内容などについて対話させて頂くことは、大変勉強になりました。また、旧寺野研究室の山口ひとみ様、山村研究室の西文恵様には、事務手続き等、様々なご協力を頂きました。

これからも、旧寺野研究室のメンバーやOBOGからなるコミュニティがますます発展していくことを願っております。最後に、博士課程での経験を基に、今後も研究や日常業務を通じて、研鑽を続けていく所存です。この研究活動を支えて下さった全ての皆様に、改めて感謝いたします。

参考文献

- [1] 松田稔樹. 特集 「教育の変革を促すシミュレーション &ゲーミング」 の趣旨と概要. シミュレーション &ゲーミング, Vol. 27, No. 2, pp. 47–48, 2018.
- [2] Sebastiaan Meijer. The organisation of transactions: Studying supply networks using gaming simulation, Vol. 6. Wageningen Academic Publishers, 2009.
- [3] 新井潔. ゲーミングシュミレーションとは何か. ゲーミングシュミレーション, pp. 1–43, 1998.
- [4] Yusuke Toyoda. A framework of simulation and gaming for enhancing community resilience against Large-Scale earthquakes: Application for achievements in japan. Simul. Gaming, Vol. 51, No. 2, pp. 180–211, April 2020.
- [5] 市川新, 中村美枝子. ゲーミング専門語の中核編纂の試み. シミュレーション&ゲーミング, Vol. 13, No. 2, pp. 198–209, 2003.
- [6] David Crookall. Serious Games, Debriefing, and Simulation/Gaming as a Discipline:. <http://dx.doi.org/10.1177/1046878110390784>, Vol. 41, No. 6, pp. 898–920, jan 2011.
- [7] 中村美枝子. ゲーミングシミュレーションにおけるファシリテーション. ゲーミングシミュレーション, pp. 169–206. 日科技連, 1998.
- [8] J van den Hoogen, J C Lo, and S A Meijer. The debriefing of research games: a structured approach for the validation of gaming simulation outcomes. In Proceedings of the 45th conference of the international simulation and gaming association (ISAGA), pp. 599–610. s.n., 2014.

- [9] Willy Christian Kriz. A Systemic-Constructivist approach to the facilitation and debriefing of simulations and games. Simul. Gaming, Vol. 41, No. 5, pp. 663–680, October 2010.
- [10] Matteo Golfarelli, Stefano Rizzi, and Andrea Proli. Designing what-if analysis: towards a methodology. In Proceedings of the 9th ACM international workshop on Data warehousing and OLAP, DOLAP '06, pp. 51–58, New York, NY, USA, November 2006. Association for Computing Machinery.
- [11] Morris S Y Jong, Junjie Shang, Fong-Iok Lee, and Jimmy H M Lee. An evaluative study on VISOLE—Virtual interactive Student-Oriented learning environment. IEEE Trans. Learn. Technol., Vol. 3, No. 4, pp. 307–318, 2010.
- [12] Guillaume Lamé and Rebecca K Simmons. From behavioural simulation to computer models: how simulation can be used to improve healthcare management and policy. BMJ Simul Technol Enhanc Learn, Vol. 6, No. 2, pp. 95–102, March 2020.
- [13] Mardochee Reveil and Yao-Hsuan Chen. Predicting and preventing COVID-19 outbreaks in indoor environments: an agent-based modeling study. Sci. Rep., Vol. 12, No. 1, p. 16076, September 2022.
- [14] Fumitoshi Kato. Facilitation in communication: Toward a study of an educational gaming simulation. In Rei Shiratori, Kiyoshi Arai, and Fumitoshi Kato, editors, Gaming, Simulations, and Society: Research Scope and Perspective, pp. 71–80. Springer Tokyo, Tokyo, 2005.
- [15] David Crookall. Debriefing: A practical guide. September 2022.
- [16] Jannicke Baalsrud Hauge, Heinrich Söbke, Thomas Bröker, Theodore Lim, Angelo Marco Luccini, Maksims Kornevs, and Sebastiaan Meijer. Current competencies of game facilitators and their potential optimization in higher education: Multimethod study. JMIR Serious Games, Vol. 9, No. 2, p. e25481, May 2021.
- [17] Hiroshi Fujimori, Yasushi Kuno, Hiroaki Shirai, Hisatoshi Suzuki, and Takao Terano. Alexander islands: GSSM tiny business simulator on the WWW. ABSEL, Vol. 26, , March 1999.

-
- [18] Motonari Tanabu. Agent based modeling for business gam-ing simulation and application for supply chain management education. In Proceedings of the 2010 International Conference on E-Business Intelligence, pp. 481–490, Paris, France, December 2010. Atlantis Press.
- [19] Bill Roungas, Sebastiaan Meijer, and Alexander Verbraeck. The tacit knowledge in games: from validation to debriefing. Int. Simulation and Gaming Association Conf., pp. 74–83, 2019.
- [20] 加藤文俊. メディアとしてのゲーミングシミュレーション. ゲーミングシミュレーション, pp. 125–168. 日科技連, 1998.
- [21] C. S. Greenblat. Designing games and simulations: An illustrated handbook. SAGE Publications Inc., 1988.
- [22] Masato Kobayashi and Takao Terano. Exploring business gaming strategies by learning agents, 2005.
- [23] Yuji Shinoda, Mina Ryoike, Takao Terano, and Yoshiteru Nakamori. Design of a software agent for business gaming simulation. Journal of Systems Science and Systems Engineering, Vol. 15, pp. 83–94, 3 2006.
- [24] Hiroshi Deguchi. Economics as an Agent-based Complex System: Toward Agent-based Social Systems Sciences. Springer, 2004.
- [25] Hiroshi Deguchi, Tomoya Saito, Manabu Ichikawa, and Hideki Tanuma. Simulated tabletop exercise for risk management-anti bio-terrorism scenario simulated tabletop exercise. In Developments in Business Simulation and Experiential Learning: Proceedings of the Annual ABSEL Conference, Vol. 38, 2011.
- [26] 松井啓之. 社会システムとゲーミングシミュレーション. 情報処理学会研究報告知能と複雑系 (ICS), Vol. 2001, No. 1 (2000-ICS-123), pp. 49–54, 2001.
- [27] Richard D. Duke. Gaming: the future’s language. SAGE Publications Inc., first edition, 1974.

- [28] 出口弘. 社会的問題解決手法としてのゲーミング. ゲーミングシミュレーション, 日科技連出版社, 第 2 章, pp. 45–82, 1998.
- [29] Masaaki Kunigami and Takao Terano. Amalgamating agent and gaming simulation to understand social-technical systems. In Simulation and Gaming for Social Design, pp. 217–233. Springer, 2021.
- [30] 寺野隆雄. ケースとゲームでビジネスを学ぶ. 計測と制御, Vol. 46, No. 1, pp. 44–50, 2007.
- [31] David A Kolb. Experiential Learning: Experience as the Source of Learning and Development. FT Press, December 2014.
- [32] Markus Ulrich. Links between experiential learning and simulation & gaming. In Proceedings of the 28th Annual International Conference of the International Simulation and Gaming Association, pp. 269–275, 1997.
- [33] Peter Jarvis. Adult and continuing education: Theory and practice. Psychology Press, 1995.
- [34] 中原淳. 経験学習の理論的系譜と研究動向. 日本労働研究雑誌, Vol. 55, No. 10, pp. 4–14, 2013.
- [35] Rob J G Jansen and Marino van Zelst. The multiple facilitator: Scientists, sages and rascals. Simul. Gaming, Vol. 52, No. 3, pp. 273–289, June 2021.
- [36] David C Lane. On a resurgence of management simulations and games. J. Oper. Res. Soc., Vol. 46, No. 5, pp. 604–625, May 1995.
- [37] Timothy C Clapper. Situational interest and instructional design: A guide for simulation facilitators. Simul. Gaming, Vol. 45, No. 2, pp. 167–182, April 2014.
- [38] Linda Costigan Lederman. Debriefing: A critical reexamination of the postexperience analytic process with implications for its effective use. Simulation & Games, Vol. 15, No. 4, pp. 415–431, 1984.

- [39] Charles F Petranek, Susan Corey, and Rebecca Black. Three levels of learning in simulations: Participating, debriefing, and journal writing. Simulation & gaming, Vol. 23, No. 2, pp. 174–185, 1992.
- [40] Barbara Steinwachs. How to facilitate a debriefing. Simulation & gaming, Vol. 23, No. 2, pp. 186–195, 1992.
- [41] Anna-Sofia Alklind Taylor. Facilitation matters : A framework for instructor-led serious gaming. PhD thesis, 2014.
- [42] Rens Kortmann and Vincent Peters. Becoming the unseen helmsman - game facilitator competencies for novice, experienced, and non-game facilitators. Simul. Gaming, Vol. 52, No. 3, pp. 255–272, June 2021.
- [43] Beiyu Yang and Motonari Tanabu. The effectiveness of sdm method in business simulation game. In Developments in Business Simulation and Experiential Learning: Proceedings of the Annual ABSEL conference, Vol. 40, 2013.
- [44] Beiyu Yang and Motonari Tanabu. Facilitating knowledge acquisition with surrogate decision maker method in business simulation game. Innovation and Supply Chain Management, Vol. 7, No. 4, pp. 157–167, 2013.
- [45] Clark C Abt. Serious Games. University Press of America, 1987.
- [46] S A Meijer and G J Hofstede. Simulation games for improving the human orientation of production management. In Current trends in production management. Proceedings of IFIP WG 5.7 Working conference on human aspects in production management, October 5-9, 2003, pp. 58–64. Shaker Verlag, 2003.
- [47] Dean S Dorn. Simulation games: One more tool on the pedagogical shelf. Teach. Sociol., Vol. 17, No. 1, pp. 1–18, 1989.
- [48] John V Dempsey, Linda L Haynes, Barbara A Lucassen, and Maryann S Casey. Forty simple computer games and what they could mean to educators. Simul. Gaming, Vol. 33, No. 2, pp. 157–168, June 2002.

- [49] Bernard O Koopman. The optimum distribution of effort. OR, Vol. 1, No. 2, pp. 52–63, February 1953.
- [50] 國上真章, 奥村隆一, 菊地剛正, 坂田顕庸, 寺野隆雄. 社会・組織シミュレーションにおけるエージェントの自己資源配分・成長モデル. 人工知能学会第二種研究会資料, Vol. 2021, No. BI-017, p. 10, 2021.
- [51] R Shishko and R Aster. NASA systems engineering handbook. NASA systems engineering handbook/by, 1995.
- [52] 國上真章, 寺野隆雄. エージェントシミュレーションとゲーミングによるシステム思考の実践にむけて. 計測と制御, Vol. 59, No. 12, pp. 926–929, 2020.
- [53] Jean Ensminger. Reputations, trust, and the principal agent problem. Trust in society, Vol. 2, pp. 185–201, 2001.
- [54] 出口弘. エージェントベース社会システム科学の数理的基礎—社会学習動学による規範ゲームの数理的基礎付け—. 理論と方法, Vol. 19, No. 1, pp. 67–86, 2004.
- [55] Akinobu Sakata, Takamasa Kikuchi, Ryuichi Okumur, Masaaki Kunigami, Atsushi Yoshikawa, Masayuki Yamamura, and Takao Terano. The Shin-Life Career Game: Pursuing Your New Life Style through Gaming Simulation. The Thirteenth Int. Conf. on Information, Process, and Knowledge Management (eKNOW 2021), pp. 14–20, 2021.
- [56] Volker Grimm, Uta Berger, Finn Bastiansen, Sigrunn Eliassen, Vincent Ginot, Jarl Giske, John Goss-Custard, Tamara Grand, Simone K Heinz, Geir Huse, Andreas Huth, Jane U Jepsen, Christian Jørgensen, Wolf M Mooij, Birgit Müller, Guy Pe’er, Cyril Piou, Steven F Railsback, Andrew M Robbins, Martha M Robbins, Eva Rossmanith, Nadja Rüger, Espen Strand, Sami Souissi, Richard A Stillman, Rune Vabø, Ute Visser, and Donald L DeAngelis. A standard protocol for describing individual-based and agent-based models. Ecol. Modell., Vol. 198, No. 1-2, pp. 115–126, September 2006.

- [57] Volker Grimm, Uta Berger, Donald L DeAngelis, J Gary Polhill, Jarl Giske, and Steven F Railsback. The ODD protocol: A review and first update. Ecol. Modell., Vol. 221, No. 23, pp. 2760–2768, November 2010.
- [58] 寺野隆雄. エージェント・ベース・モデリングへの招待. オペレーションズ・リサーチ: 経営の科学, Vol. 49, No. 3, pp. 131–136, 2004.
- [59] Abraham Charnes, William W Cooper, and Edwardo Rhodes. Measuring the efficiency of decision making units. European J. of operational research, Vol. 2, No. 6, pp. 429–444, 1978.
- [60] 刀根, 筒井薫, 美樹, 丸山, 幸宏, 濱口, 福山ほか. 経営効率性の測定の基礎: DEA 分析の事例で学ぶ生産性・効率性向上への挑戦. 日本評論社, 第1版, 2022.
- [61] Masaaki Kunigami, Takamasa Kikuchi, and Takao Terano. A knowledge extraction from epidemic control simulation. eKNOW 2021, The Thirteenth International Conference on Information, Process, and Knowledge Management, pp. 21–26.
- [62] 星埜雅子, 稲積宏誠. 包絡分析法を用いたクラスタリング手法の提案 -遺伝子発現データを対象として-. 人工知能学会全国大会論文集, Vol. JSAI05, pp. 192–192, 2005.
- [63] Rung-Wei Po, Yuh-Yuan Guh, and Miin-Shen Yang. A new clustering approach using data envelopment analysis. Eur. J. Oper. Res., Vol. 199, No. 1, pp. 276–284, November 2009.
- [64] Elham Shadkam and Mehdi Bijari. Multi-objective simulation optimization for selection and determination of order quantity in supplier selection problem under uncertainty and quality criteria. Int. J. Adv. Manuf. Technol., Vol. 93, No. 1, pp. 161–173, October 2017.
- [65] Hossein Sameie and Meysam Arvan. A simulation-based data envelopment analysis (DEA) model to evaluate wind plants locations. Decis. Sci. Lett., Vol. 4, No. 2, pp. 165–180, 2015.

- [66] David Berre, Jonathan Vayssières, Jean-Philippe Boussemart, Hervé Leleu, Emmanuel Tillard, and Philippe Lecomte. A methodology to explore the determinants of eco-efficiency by combining an agronomic whole-farm simulation model and efficient frontier. Environmental Modelling & Software, Vol. 71, pp. 46–59, September 2015.
- [67] A Azadeh, T Nazari, and H Charkhand. Optimisation of facility layout design problem with safety and environmental factors by stochastic DEA and simulation approach. Int. J. Prod. Res., Vol. 53, No. 11, pp. 3370–3389, June 2015.
- [68] Tamás Koltai and Judit Uzonyi-Kecskés. Analysis of the learning process in a production simulation game with DEA using cumulative data. Miskolci Egyetem, 2013.
- [69] T Koltai and J Uzonyi-Kecskés. The comparison of data envelopment analysis (DEA) and financial analysis results in a production simulation game. Acta Polytechnica Hungarica, Vol. 14, No. 4, pp. 167–185, January 2017.
- [70] A. Raith, O. Perederieieva, F. Fauzi, K. Harton, A. Lee, K.M. Lin, H. Priddey, and M. Rouse. pyDEA.
- [71] A. Raith, P. Rouse, and L.M. Seiford. Benchmarking using data envelopment analysis: Application to stores of a postand banking business. In Multiple Criteria DecisionMaking and Aiding, pp. 1–39. 2019.
- [72] Vladimir I Levenshtein, et al. Binary codes capable of correcting deletions, insertions, and reversals. Soviet physics doklady, Vol. 10, No. 8, pp. 707–710, 1966.
- [73] J Ross Quinlan. Program for machine learning. C4.5, 1993.
- [74] J Ross Quinlan. C4.5: programs for machine learning. Elsevier, 2014.
- [75] Sabine Landau, Morven Leese, Daniel Stahl, and Brian S Everitt. Cluster analysis. John Wiley & Sons, 2011.
- [76] Fionn Murtagh and Pedro Contreras. Algorithms for hierarchical clustering: an overview. Wiley Interdisciplinary Reviews: Data Mining and Knowledge Discovery, Vol. 2, No. 1, pp. 86–97, 2012.

-
- [77] François Petitjean, Jordi Inglada, and Pierre Gancarski. Satellite image time series analysis under time warping. IEEE Transactions on Geoscience and Remote Sensing, Vol. 50, No. 8, pp. 3081–3095, 2012.
- [78] Eamonn Keogh, Stefano Lonardi, and Chotirat Ann Ratanamahatana. Towards parameter-free data mining. pp. 206–215, New York, NY, USA, 2004. Association for Computing Machinery.
- [79] Michail Vlachos, Marios Hadjieleftheriou, Dimitrios Gunopulos, and Eamonn Keogh. Indexing multidimensional time-series. The VLDB Journal, Vol. 15, No. 1, pp. 1–20, 2006.
- [80] Weighted dynamic time warping for time series classification. Pattern Recognition, Vol. 44, No. 9, pp. 2231–2240, 2011.
- [81] scikit-learn. <https://scikit-learn.org/>.
- [82] Wen-Chih Chen and Wei-Jen Cho. A procedure for large-scale DEA computations. Comput. Oper. Res., Vol. 36, No. 6, pp. 1813–1824, June 2009.
- [83] 中野健次, 寺野隆雄. ケースとビジネスゲームの融合—ビール会社経営における意思決定の学習—. シミュレーション &ゲーミング, Vol. 16, No. 1, pp. 13–27, 2006.
- [84] 越山修, 國上真章, 吉川厚, 寺野隆雄. ビジネスゲーム学習者の行動プロセスの研究—改良したパフォーマンスシートを用いて—. シミュレーション &ゲーミング, Vol. 21, No. 2, pp. 86–95, 2011.
- [85] 越山修. ビジネスゲームにおける学習行動の分析に関する研究. PhD thesis, 東京工業大学, 2011.
- [86] Masaaki Kunigami, Takamasa Kikuchi, and Takao Terano. A formal model of managerial decision making for business case description. In Fernando Koch, Atsushi Yoshikawa, Shihan Wang, and Takao Terano, editors, Evolutionary Computing and Artificial Intelligence: Essays Dedicated to Takao Terano on the Occasion of His Retirement, pp. 21–26. Springer Singapore, Singapore, 2019.

-
- [87] 菊地剛正, 國上真章, 高橋大志, 鳥山正博, 寺野隆雄, Others. 経営意思決定表現モデルを用いたビジネスケースとエージェントモデルの意思決定過程の形式的記述. 情報処理学会論文誌, Vol. 60, No. 10, pp. 1704–1718, 2019.
- [88] 中野健次. ケースとビジネスゲームの融合による意思決定学習に関する研究. PhD thesis, 東京工業大学, 2007.
- [89] 後藤裕介. 複数の分析関心に基づく社会シミュレーション・ログの階層的分類と可視化手法. 計測自動制御学会論文集, Vol. 56, No. 10, pp. 463–474, 2020.
- [90] 奥村隆一. 人的資本形成における能力開発手法としての自己学習の研究. PhD thesis, 東京工業大学, 2021.

研究業績一覧

学術雑誌（査読付き）

1. Akinobu Sakata, Takamasa Kikuchi, Ryuichi Okumura, Masaaki Kunigami, Atushi Yoshikawa, Masayuki Yamamura, Takao Terano. “Methodology for Extracting Knowledge from a Gaming Simulation Using Data Envelopment Analysis.”, International Journal on Advances in Software Vol.14, No.1&2, pp.107–121.2021
2. Akinobu Sakata, Takamasa Kikuchi, Masaaki Kunigami, Atushi Yoshikawa, Masayuki Yamamura, Takao Terano. “Extracting Branch Factors from a Gaming Simulation Using Log-Cluster Analysis ”, Journal of Advanced Computational Intelligence and Intelligent Informatics Vol.27, No.2, pp.223–234.March 2023

国際会議（査読付き）

1. Akinobu Sakata, Takamasa Kikuchi, Ryuichi Okumura, Masaaki Kunigami, Atsushi Yoshikawa, Masayuki Yamamura, Takao Terano. ”Uncovering Users’ Decisions through Serious Game Playing with A Formal Description Method”, In the 13th China-Japan International Workshop on Information Technology & Control Applications (ITCA2020), September 2020
2. Akinobu Sakata, Takamasa Kikuchi, Ryuichi Okumura, Masaaki Kunigami, Atsushi Yoshikawa, Masayuki Yamamura, Takao Terano. ”The Shin-Life Career Game: Pursuing Your New Life Style through Gaming Simulation”, In the Thirteenth International Conference on Information, Process, and Knowledge Management (eKNOW2021), pp.14–20, 2021
3. Akinobu Sakata, Takamasa Kikuchi, Ryuichi Okumura, Masaaki Kunigami, Atsushi Yoshikawa, Masayuki Yamamura, Takao Terano. ”A Basic Research to Develop a Method to Classify Game Logs and Analyze them by Clusters”, In

the 7th International Workshop on Advanced Computational Intelligence and Intelligent Informatics (IWACIII 2021), 2021

4. Akinobu Sakata, Takamasa Kikuchi, Ryuichi Okumura, Masaaki Kunigami, Atsushi Yoshikawa, Masayuki Yamamura, Takao Terano. "A Knowledge Extraction from Gaming Logs", Artificial Intelligence of and for Business (AI-Biz2021), JSAI International Symposia on AI 2021 (IsAI-2021), November 2021