別紙２

令和６年度　防衛装備庁
安全保障技術研究推進制度

研究成果報告書
計算力学とゲームAIを応用した
OODA意思決定・群制御の研究

令和７年５月

クラスターダイナミクス株式会社

別紙２

本報告書は、防衛装備庁の安全保障技術研究推進制度による委託業務として、クラスターダイナミクス株式会社が実施した令和５年度から令和６年度にかけて実施した「計算力学とゲームAIを応用したOODA意思決定・群制御の研究」の成果を取りまとめたものです。

目次

０．　研究背景 1
　０．１　本研究の目的 1
１．　委託業務の目的 2
　１．１　研究課題の最終目標及び要素課題 2
　　【最終目標】 2
　　【要素課題】 8
２．　研究開始時に設定した研究目標の達成度 10
　２．１　最終目標の達成度 10
　２．２　要素課題の達成度 11
３．　委託業務における研究の方法及び成果 13
　３．１　成果総括 14
　　３．１．１　総括概要 14
　　３．１．２　主要成果 16
　　３．１．３　本研究の位置付けと成果の自己評価 36
　　３．１．４　本研究に関する関連用語および略語 44
　３．２　実施項目①OODA 群制御 AI アーキテクチャの研究 49
　　３．２．１　本研究課題に関する概念整理 49
　　３．２．２　既存研究の整理 53
　　３．２．３　課題の深堀と本質的構造の定義：二層スウォームの統合 57
　　３．２．４　無人機マルチエージェント技術体系の構築 59
　　３．２．５　新知能原理「絵図・知識・運動系 AI」の提案 62
　　３．２．６　マルチエージェントシステム設計論 67
　　３．２．７　新アーキテクチャの設計・定義 68
　　３．２．８　OODA 群制御 AI(意思決定・群制御の統合知能)の構築 70
　　３．２．９　RCT 世界モデル(AI 認知思考制御基盤)の構築 71
　　３．２．１０　IS-Physics モデル規約：意思決定と群制御の統合モデル記述規約 72
　　３．２．１１　汎用マルチエージェント基盤 MAARC 83
　３．３　実施項目②AI ソルバの構築 89
　　３．３．１　成果概要 89
　　３．３．２　システム概要 92
　　３．３．３　AI 学習環境の構築 93
　　３．３．４　AI ソルバアーキテクチャ 98
　　３．３．５　機械学習モデルの調査 101
　　３．３．６　AI ソルバ(機械学習系 AI 適用)の研究 105
　　３．３．７　AI 性能評価：スマート交通シナリオ・ロジック支援型 AI(モデルベース機械学習) 106
　３．４　実施項目③ロジックソルバの構築 110
　　３．４．１　成果概要 110
　　３．４．２　ロジックソルバ構成 110
　　３．４．３　トラフィックソルバ 111
　　３．４．４　マップソルバ 123
　　３．４．５　タスクソルバ 128
　３．５　実施項目④OODA 群制御 AI システムの構築と試験実施 129
　　３．５．１　成果概要 129

３．５．２ システム概要 130
３．５．３ タスクの制御 131
３．５．４ UI 133
３．５．５ AI 学習環境との連接 140
３．５．６ 高度化２「工場作業員誤侵入危険回避」対応 141
３．５．７ 高度化３「捜索・救難 UAV/UGV 混在 3D 化対応」 146
３．５．８ マップ切替 147
３．５．９ ノード・ライン表示制御 152
３．６ 実施項目⑤仮想テスト環境の構築と試験実施 153
３．６．１ 成果概要 153
３．６．２ システム概要 154
３．６．３ 仮想化オブジェクト 155
３．６．４ UI 159
３．６．５ 動画再生ファイル出力 167
３．６．６ 高度化２「工場作業員誤侵入危険回避」対応 168
３．６．７ 高度化３「捜索・救難 UAV/UGV 混在 3D 化対応」 170
３．７ 実施項目⑥実機テスト環境の構築と試験実施 171
３．７．１ 成果概要 171
３．７．２ システム概要 173
３．７．３ CP 連接（サイバー・フィジカル連接）方式 174
３．７．４ スウォーム IF 175
３．７．５ 実施システムの最終構成 177
３．７．６ 実機システムの調達と基礎動作検証 179
３．７．７ 実機 CPS テスト環境の構築 182
３．７．８ 実機テストの実施 188
４． 委託業務全体の成果 202
４．１ 計画時に想定していなかった成果（副次的成果）や、目標を超える成果 202
４．１．１ 副次的成果 202
４．２ 研究課題の発展性（間接的成果を含む） 203
４．２．１ 見通し 203
４．２．２ 今後の発展・波及における主なボトルネック 204
４．２．３ 個別の取組み 205
４．３ 研究成果の発表・発信に関する活動 205
５． プロジェクトの総合的推進 206
５．１ 研究実施体制とマネジメント 206
５．２ 経費の効率的執行 206
６． まとめ、今後の予定 207
６．１ まとめ 207
６．２ 今後の予定 207
７． 研究発表、知的財産権等の状況 209

０．　研究背景

０．１　本研究の目的

本研究で実現したい内容は、二つのユースケース「工場倉庫のAGV搬送工程の運用管制」及び「重要拠点のUxVによる警戒監視」における実用的なシナリオに対応できるように、マルチエージェント制御システムの頭脳部分を高度化することである。即ち、意思決定と実機制御のループ過程を、システムの階層構造を踏まえ自律化する技術、及び高い信頼性を有する階層的な自律アーキテクチャを獲得することが本研究の目的である。

ここで、信頼性について補足説明する。産業レベルの実用化には、安全性と生産性について高い信頼性が要求される。しかし、自律化技術であるAI・機械学習は、推論結果が確率的あることから本質的に誤判断する可能性がある。更に、学習環境から逸脱した未知環境に遭遇した場合、誤判断の確率が高くなる。この誤判断が発生しても、安全性や生産性への影響を最小化できる高い信頼性を保つアーキテクチャを得ることも本研究の目的のひとつである。

以上より、獲得したいマルチエージェント制御システムの概要を図０．１－１に示す。運用環境は、リスクを含む未知環境である。任務リソースは階層的な構造をなし、マルチエージェント制御システムは、配下エージェントを遠隔制御して、観測、状況認識、計画立案、行動実行のループ過程を自律的に回す。具体的には、運用環境を観測し、配下や運用フィールドの状態を認識し、必要に応じて制御者に状況を提示する。そして、上位システムの指示受信や異常検知をトリガーに、相手エージェントやリスク事象の状況認識を行い、無人機の行動計画を決定し、遠隔制御を行うものである。

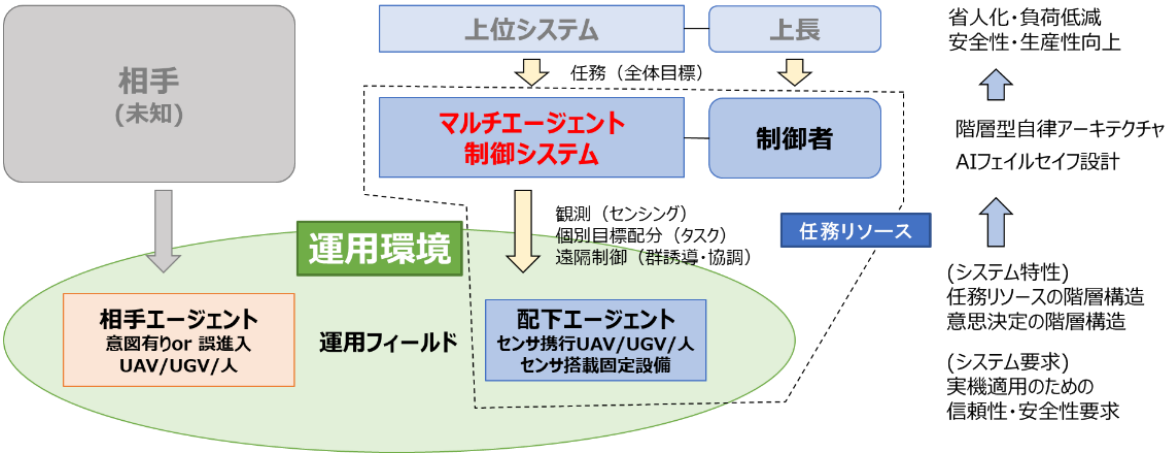

図０．１－１　実用シナリオのマルチエージェントシステムの全体像

１．委託業務の目的

１．１ 研究課題の最終目標及び要素課題

【最終目標】

「**OODA 群制御 AI アーキテクチャ**」に準拠した**マルチエージェント制御システム「OODA 群制御 AI システム」**(略称:OODA MAC AI (OODA Multi-Agent Control AI System))(以下、本システムという)の獲得を目指す。詳細を下記(1)に示す。(ここで、OODA を冠する理由は、意思決定が動的な未知環境を対象とすることから、米軍や DARPA が採用しビジネス面でも広まりつつある OODA ループ意思決定理論をアーキテクチャのベースとしたため。)

本システムは次の**３つの特徴**を備えることを目指す。ひとつ目は、計算力学を応用した運用空間離散化データモデルにより、UAV/UGV の**異種混在**、2D/3D の運用空間でも同一のシステムで機能するアーキテクチャを有することである。二つ目は、ゲーム AI を応用したエージェントの**階層的な意思決定に対応**できるアーキテクチャと機械学習環境を有することである。三つ目は、**ソフトウェアファースト設計**[1]に準拠し、本システムの機能が中央側でもエッジ側でも実現できるアーキテクチャを有することである。これらの特徴を踏まえ要素課題の対応を行う。詳細を下記(2)に示す。

上記の最終目標について、戦略レベルの問題解決を含む社会実装に適した例題を実用シナリオとして設定し、デモンストレーションにより評価指標と数値目標の検証を行うことを目指す。詳細を下記(3)に示す。

(1) システムの構成と役割

本システムは、以下に示すシステム構成を備え、以下の運用環境において期待される役割を果たすことを目指す。

(ア)システム構成

① UI(ユーザインターフェース)機能を備えること。UI は、GUI(グラフィカルユーザインタフェース)、及び入出力ファイル等を含む。ユーザの意思決定を支援するために必要な判断根拠等の情報を表示・出力する。

② 記憶機能としてデータモデルを備える。データモデルには、階層型空間離散化マップ、及びエージェントのタスクモデル等を含む。実装の形式は、機能に要求される処理性能に応じて決定する。

③ 階層的な意思決定と実施を行う OODA 意思決定・群制御の機能を備える。これらは、ロジックソルバと AI ソルバで構成される。ロジックソルバとは、ルールベースのアルゴリズムモジュールである。AI ソルバは機械学習モデルを用いたアルゴリズムモジュールである。

④ 配下エージェント等とのハードウェア IF(インターフェース)を備える。配下エージェントは、無人機、作業員、設備等が含まれる。これらは、運用環境の観測機能と実行機能を備える。また、将来的に配下エージェントでも上記③の OODA 意思決定・群制御が行えるように、ソフトウェアファーストの設計思想に従って各機能の可搬性を高めることに留意する。

⑤ 本システムは、ACS (エージェント制御システム) に搭載され、ACS のタスク管理機能と連携して動作する。

(イ)システムの運用環境

① 運用環境は、動的な未知環境、即ち不完全情報ゲームの世界である。

② この環境には、本システム、本システムのユーザ(運用責任者)、本システムの配下エージェントに加え、相手エージェントが存在する。

③ この相手エージェントは、その存在の有無、その行動等が未知要素となる。この未知要素は、配下エージェントの観測により既知となる。

[1] ソフトウェアファースト設計とは、システム製品の開発において、ソフトウェアによって実現すべき機能・性能を最初に設計し、そのソフトウェアの機能を実現するハードウェアを設計・選定する設計思想である。ソフトウェア工学ではオブジェクト指向、機械工学ではモジュール設計と同義である。

(ウ)システムの役割

① 本システムは、マルチエージェントの意思決定や実機制御において、OODA ループを構成する各機能を担い、ユーザの意思決定を支援する。

② ユーザは、本システムの支援を受けて状況認識を行い、配下エージェントの行動の最終決定権を有する。即ち、通常時(定常時・非定常時)は、本システムが配下エージェントの制御を自動実行する。一方、異常時は、ユーザが本システムの意思決定に介入できる。ここで、定常時とは、任務が規定通りに行われている状態を指す。非定常時は、想定内の問題に対応する状態を指す。異常時は、想定外の問題に対応する状態を指す。

③ 本システムは、観測した生データを分析し、状況や判断材料、行動計画案をユーザに提示する。

④ 本システムは、配下エージェントを遠隔制御する。制御レベルはエージェントの自律化レベルに対応する。自律エージェントへは目的地や経路情報を指示する。非自律エージェントへは衝突回避等の協調制御も行う。

⑤ 配下エージェントは、本システムに従い、単機または小集団で行動する。センシングした観測情報と自己状態を本システムに伝える。

(2) システムの設計思想と特徴

本システムは、ソフトウェアファースト設計に準拠し、計算力学及びゲーム AI を応用した階層的な意思決定機能を備えることを目指す。ソフトウェアファースト設計に準拠することで、そのソフトウェアの機能が中央側でもエッジ側でも実現できるアーキテクチャの獲得が期待できる。計算力学を応用した運用空間離散化データモデルにより 2D でも 3D でも同一のシステムで機能できるアーキテクチャの獲得が期待できる。エージェントの階層的な意思決定に対応できるゲーム AI を応用したアーキテクチャと機械学習環境の獲得が期待できる。

1. 設計思想「ソフトウェアファースト設計」に準拠

① 本研究は、複数無人機運用を前提とした意思決定支援自律 AI アーキテクチャの基礎研究のため、ソフトウェアがシステムの中核となる。よって、ソフトウェアファースト設計を適用する。

② 具体的には、実現したい機能を、IT 軸、OT 軸、意思決定階層軸で整理し、構成要素の独立性を高め、移植性を最大化するように考慮する。ここで、IT 軸(情報技術軸)は、UI、データモデル、アルゴリズム、ハードウェア IF で整理される。OT 軸(運用技術軸)は、OODA ループの各要素で整理される。意思決定階層軸は、戦略・戦術・実行の各レイヤーで整理される。言い換えると、ソフトウェア工学ではオブジェクト指向、機械工学ではモジュール設計の思想に従うことと同義である。

③ このようにソフトウェアの独立性・可搬性を高め、各ソフトウェア要素間のデータフローを適切に設計することで、中央側でもエッジ側でも同じ機能・性能を実現できる自律アーキテクチャの獲得を目指す。

④ ソフトウェアファースト設計のメリットは、優れたアーキテクチャのソフトウェアを最初に定義することで、ハードウェアや他の要素をその時点において最適なものを適用することができることにある。また、副次的なメリットとして、交換するマップ情報を離散化による ID 等で抽象化度を高めデータ量を減すことで、中央とエッジ間、エッジ同士の通信の暗号化だけでなく、抽象化データの意味復元困難さによる秘匿性の向上も期待できる。

⑤ 本研究においては、中央制御の方式でデモンストレーションを実施する。なお、UAV・UGV など 2D/3D 運動する異種混在の無人機群においてエッジ側(無人機側)で OODA 意思決定の一部または全部に将来的に対応できるように、本研究のアーキテクチャ、機能構成、データモデルに反映することを目指す。

2. 計算力学の応用

① 計算力学における流体解析や構造解析等の離散化データモデル(データ構造)を、マルチエージェントの運用空間の離散化データモデルに応用し、マルチエージェント全体の記憶機能の基盤とする。

② 参考にする計算力学の手法を例示する。座標系について全体座標系と局所座標系の概念を導入する。空間表現について、粒子法・格子法・有限要素法等の離散化手法を応用することを目指す。現象理解の方法について、視点に着目したオイラー法・ラグランジュ法の概念を応用する。データモデル間の情報交換や加工は、連成解析の手法を応用することを目指す。

③ 上記の技術を次のマルチエージェントの意思決定の技術に応用する。意思決定の階層構造に対応した記憶機能を実現するデータモデル(データ構造)を目指す。機械学

習の軽量化に資するデータモデルとモデリング手法を目指す。OODA ループの各要素における判断根拠の可視化に資するデータモデルを目指す。

3. ゲーム AI の応用
   ① ゲーム AI とマルチエージェント制御の類似性を踏まえ、次に示すゲーム AI の要素技術をマルチエージェントの意思決定と群制御への応用を目指す。
   ② ゲーム AI の意思決定アーキテクチャを OODA 群制御アーキテクチャに応用する。具体的には、記憶機能と判断機能の配置やデータフローを参考にする。
   ③ 空間階層化・時間階層化の技術を、計算力学の空間離散化・時間離散化技術を踏まえ、意思決定の空間離散化データモデルに応用することを目指す。
   ④ キャラクター制御と階層型ゴール・階層型タスクの設計を、エージェントのタスク管理に応用することを目指す。
   ⑤ 戦略ゲーム AI の機械学習モデルと AI 学習環境のアーキテクチャを踏まえ、本システムの機械学習モデルと AI 学習環境のアーキテクチャに応用することを目指す。

(3) 戦略レベルの課題を含む実用シナリオとデモンストレーション

戦略レベルの問題解決を含む課題、及び社会実装に適した実用的な例題として、表１及び表２に示す実用シナリオについて、デモンストレーションを実施することを目指す。

デモンストレーションにおいて、表３に示す各実用シナリオの最適化問題について、目的関数や対処方法を考慮し、期待値(数値目標・評価指標)の検証を行うことを目指す。

表１　実用シナリオの概要

区分	実用シナリオ名称	テーマ	課題	ゲーム種類	エージェント種類	運用空間次元	未知要素
参考１	空港での UAV 鳥類追い払い	実行レベル 問題解決 ・群誘導協調	数百機の UAV の状態変化に対応するスウォーム飛行実証と機械学習適用	完全情報ゲーム	UAV	3D を 2D 運用(z=ゼロ)	(なし)
参考２(基準)	工場倉庫の AGV 搬送	戦術レベル 問題解決 ・経路探索	数百機の AGV 全体の状態変化に対応する交通協調制御の実現	完全情報ゲーム	UGV	3D を 2D 運用(z=ゼロ)	(なし)
本研究高度化１	工場倉庫の AGV 搬送	戦略レベル 内部問題解決 ・交通全体最適	全体的な渋滞回避と交通制御、搬送タスクの担当者と目的地選定の最適化	完全情報ゲーム	UGV	3D を 2D 運用(z=ゼロ)	(なし)
本研究高度化２	工場倉庫の AGV 搬送	戦略レベル 外部問題解決 ・突発事象対応	人誤侵入・AGV 故障による突発的な通行障害の影響を最小化	完全情報ゲーム	UGV 定点カメラ	3D を 2D 運用(z=ゼロ)	(なし)
本研究高度化３	重要拠点の UxV 遠隔監視	静的な未知要素への対応 ・災害初動対応	被災状況を観測し、全体状況(目的地や経路状態)を認識し、任務タスクを生成し対処	準完全情報ゲーム	UAV UGV 定点カメラ	3D 運用(z 有効)	要救助者の位置 経路被害レベル
本研究高度化４	重要拠点の UxV 遠隔監視	動的な未知要素への対応 ・域内警戒監視	部外者の侵入を定点観測・定期観測し、侵入を認識し、任務タスクを生成し対処	不完全情報ゲーム	UAV UGV 定点カメラ	3D 運用(z 有効)	侵入者の有無と動向

備考：

1) 本研究は、上記表の区分にある本研究高度化１～４の順で各実用シナリオ・テーマへの対応を進める。

2) 参考１・2 は本研究の位置付けを明確にするために先行研究の概要を示すものである。我々は、異種協調・多機数対応・実機安全を前提としたマルチエージェントの意思決定・群制御について、計算力学を応用した制御系デジタルツインに基づくソフトウェアで実現する研究を、実行レベル、戦術レベル、戦略レベルへと段階を踏んで実施している。本研究の成果の数値目標の比較基準として、参考 2 の生産性指標を採用する。ここで、参考１（先行研究１）は、令和元年度に防衛装備庁の安全保障技術研究推進制度に採択された「機械学習と物理学ベース群知能による状況適応型群制御の研究」を指す。参考 2（先行研究２）は、先行研究１の課題へ対応し社会実装を進めるため、顧客プロジェクトで実施した「工場の生産工程における AGV 搬送の制御アルゴリズム創発・デジタルツイン対応プロジェクト」を指す。

3) 実用シナリオ１「工場倉庫の AGV 搬送」の解説：
   ① 社会実装が最も近い工場倉庫の搬送工程の AGV(UGV)運用管制任務を想定する。
   ② 意思決定の範囲をこれまでより上位の戦略レベルに拡張し自律化することを目指す。
   ③ 戦略レベルの意思決定において、工程全体の最適化を目指す。具体的には、エージェントの移動の流れを流体に見立てて、その分布を考慮した物流の清流化・渋滞防止を目指す。また、配車機能の高度化を行う。具体的には、上位の搬送タスクに対し、最適なエージェントと目的地を選定し、渋滞を考慮して動的に配車、経路探索、及び交通制御を行う。
   ④ 未知環境のリスク対応として、突発事象への対応を目指す。突発事象とは、運用規定に外れた事象、運用者が意図しない事象をいう。この突発事象をリスクとして扱う。具体的には、作業員による意図しない UGV 経路への誤侵入、及び AGV の突発停止に対応することを目指す。ここで、突発停止とは、故障等により突発的に中央制御装置から観測・遠隔制御できなくなることをいう。この突発停止を観測し、リスク対処中はリスク発生場所を他の AGV は回避し、リスク発生場所へ観測任務を割り当てた AGV の配車を行うことを目指す。

4) 実用シナリオ２「重要拠点の UxV 遠隔監視」の解説：
   ① 重要拠点の UxV 遠隔監視任務を想定する。動的な相手(リスク)がいる場合を想定し、未知要素の難度を高めることを目指す。同一のソフトウェアで、UGV(AGV)と UAV に対応できることを目指す。
   ② 戦略レベルの意思決定において、動的リスクの観測と対処の要素を含めることを目指す。具体的には、定常業務と非定常業務(緊急時対応)に対応できることを目指す。定常業務では、「①複数 UAV が定期的に拠点内を巡回する。② 巡回は未確認領域を優先して行う。③確認した領域は一定時間を経過したら再探索する。」ことを目指す。非定常業務では、「①センサが侵入者を検知する。②システムが任務計画・飛行計画策定する。③UAV が捜索する。④UAV の交代を考慮する」ことを目指す。
   ③ 本研究では、未知リスクを静的・動的の２種類に分けて、２段階で課題への対応を行う。

表２　実用シナリオと各意思決定レベルの課題の概要

区分	実用シナリオ名称・テーマ	戦略レベルの課題（全体状況認識と資源配分）	戦術レベルの課題（最適な行動計画）	実行レベルの課題（安全な挙動）
参考１	空港での UAV 鳥類追い払い・群誘導協調	（なし）	（なし）	粒子法と流体理論を応用した群知能、及びシミュレーション予測制御に対応する。
参考２（基準）	工場倉庫の AGV 搬送・経路探索	（なし）	静的な経路探索、即ち搬送タスク受信時の経路探索に対応する。	階層型空間モデルとシミュレーション予測による交通・協調制御に対応する。
本研究高度化１	工場倉庫の AGV 搬送・交通全体最適	流体理論を応用した交通流の状況認識、及び最適な目的地と担当選定を対応する。	流体理論を応用した動的な渋滞回避経路探索に対応する。	階層型空間モデルとシミュレーション予測による交通・協調制御に対応する。
本研究高度化２	工場倉庫の AGV 搬送・突発事象対応	観測リスク情報と交通流の空間モデル連携による状況認識に対応する。	流体理論を応用したリスク回避経路探索に対応する。	階層型空間モデルとシミュレーション予測による交通・協調制御に対応する。
本研究高度化３	重要拠点の UxV 遠隔監視・災害初動対応	目的地と通行可経路に係わる状況認識､即ち UAV/UGV 構成の最適化及び最適な目的地と担当選定に対応する。	状況を観測する探索タスク経路生成に対応する。	上記交通・協調制御の UxV 異種対応、及び 3D-2D 混在対応に対応する。
本研究高度化４	重要拠点の UxV 遠隔監視・域内警戒監視	動的リスクの状況認識、即ちリスク移動予測(動的な目的地)に対応する。	警戒タスク経路生成、及び追跡タスク経路生成に対応する。	上記交通・協調制御の UxV 異種対応、及び 3D-2D 混在対応に対応する。

備考：

1) 意思決定の階層構造(レイヤー)の解説：

意思決定レイヤーは、上位から順番に戦略レベル、戦術レベル、実行レベルで構成され、それぞれの階層において解決すべき問題がある。

① 戦略レベルの問題は、全体の最適化・資源配分(リソース配分)の問題である。全体の最適化を考慮して、任務リソース(無人機、作業員、固定設備)を時間的・空間的に配分する必要がある。

② 戦術レベルの問題は、エージェントの目的地へ移動に関する行動計画を最適化する問題である。

③ 実行レベルの問題は、エージェントの行動において、物理的な安全性を確保しながら行動する問題である。

2) 未知環境とリスク対処の解説：

本研究における未知環境のレベルは、既知環境(完全情報ゲーム)、静的未知環境(準完全情報ゲーム)、動的未知環境(不完全情報ゲーム) に分類する。この順に難度が上がる。ここでリスクとは、任務を阻害する要因、安全性を阻害する要因をいう。例えば、突発事象発生により運用環境が変化し未知要素の存在する場合、運用環境に相手エージェントの意図しない侵入の可能性がある場合等である。以下にそれぞれの概要を示す。

① 既知環境は、未知リスクが無い。全ての情報が可観測である。完全情報ゲームに相当する。

② 静的未知環境は、観測によりリスクを検知することで既知環境に移行する環境をいう。リスク要因は、時間的・空間的に変化しない。これを準完全情報ゲームと称する。

③ 動的未知環境は、観測によりリスクを検知するが、リスク要因が空間的に変化し、時間的に観測部分のリスク度が復元する環境をいう。不完全情報ゲームに相当する。

表３　実用シナリオと最適化問題の期待値(数値目標と指標)

区分	実用シナリオ名称・テーマ	最適化の目的関数(評価関数)	最適化問題への対応方法	期待値(数値目標・評価指標)
参考１	空港での UAV 鳥類追い払い・群誘導協調	(対象外)	(対象外)	(対象外)
参考２(基準)	工場倉庫の AGV 搬送・経路探索	搬送時間の最小化	多機数対応を実現するための階層型視点別空間離散化マップモデル、経路探索・交通制御・シミュレーション予測制御のアルゴリズムの定式化を行った。	UGV 機数と搬送時間の比較検討を行った。顧客制御アルゴリズム比で 10%短縮した。対応台数も従来の 30 台から 800 台に増加できた。(弊社実績)
本研究高度化１	工場倉庫の AGV 搬送・交通全体最適	搬送時間の最小化	移動体の流れを流体に見立て、流体理論を交通制御に応用する。物理特性を参考に経路や区域毎の渋滞の状況認識を行い、流体理論を応用した経路探索・交通制御アルゴリズムを定式化する。また、その最適化に機械学習を適用する。	UGV 機数と搬送時間の比較検討を行う。 本研究高度化１の搬送時間を、参考２のアルゴリズムによる搬送時間を基準として、基準から 20%短縮を目指す。
本研究高度化２	工場倉庫の AGV 搬送・突発事象対応	搬送時間の最小化	作業員の誤侵入・AGV 故障による突発的な通行障害を常時観測し、事象発生時に、空間離散化マップモデルにリスクを反映する。その上で経路探索・交通制御アルゴリズムを定式化する。また、その最適化に機械学習を適用する。	UGV 機数と搬送時間の比較検討を行う。 本研究高度化２の搬送時間を、参考２から 10%短縮(本研究高度化１ケースからの悪化を 10%以下に)することを目指す。
本研究高度化３	重要拠点の UxV 遠隔監視・災害初動対応	観測時間の最小化 配送時間の最小化 合計時間の最小化	被災状況を UAV 観測し、要救助地点を目的地として認識し、被災経路は回避するように観測空間離散化マップモデルに反映する。複数目的地に対し優先順位を定め、搬送タスクを UGV に割り当て、経路探索・交通制御を実行する。また、その最適化に機械学習を適用する。	ひとつの OODA 群制御 AI システムで UGV と UAV の両方に対応することを目指す。 静的な未知リスク・準完全情報ゲームに対応できることを目指す。 多目的最適化に対応することを目指す。
本研究高度化４	重要拠点の UxV 遠隔監視・域内警戒監視	警戒時間の最小化 追跡時間の最小化	域内の定期巡回用の観測空間離散化マップモデルと探索計画アルゴリズムを定式化する。 動的リスク追跡用の観測空間離散化マップモデルを定式化する。動的リスクの行動予測は、計算力学の時間差分法を応用して行い、動的な目的地として経路探索・交通制御を実行する。また、その最適化に機械学習を適用する。	動的な未知リスク・不完全情報ゲームに対応できることを目指す。 動的リスクの観測用・追跡用の空間離散化マップモデルを定式化することを目指す。 動的リスクの行動予測を行い、動的目的地として経路探索・交通制御を実行することを目指す。

備考：

1)　中間評価時の期待値のレベルについて

本研究開始から約 10 か月後(令和６年 10 月前後)に中間評価を予定している。この中間評価では、本研究高度化１「工場倉庫の AGV 搬送・交通全体最適」のケースについて、以下の期待値の達成を目指す。

① デモ用シミュレーションモデルを作成し、搬送時間の基準値を取得する。なお、評価は効率化を観測できる必要最小限 AGV 台数・運用エリアの規模を設定し実施する。

② 流体理論を応用したアルゴリズムを仮作し搬送時間を取得する。

③ なお、数値目標が未達の場合は、数値目標と設計変数の影響を分析し、その原因を明らかにすること。

【要素課題】

● 要素課題(1)：「OODA群制御AIシステム」の階層型自律アーキテクチャ研究

（ア）状況適応型群制御の分析と階層型自律アーキテクチャへの移行検討：

動的な未知環境における意思決定理論 OODA ループをベースとしたアーキテクチャを検討し、先行研究の状況適応型群制御の分析を行い、機能を再構成する。また、OODA 機能の機能間の独立性を高めるため、データ連携のための階層的データモデルを検討し、各機能を統合する機能を明らかにし適用研究を行うことを目指す。

（イ）階層型自律アーキテクチャへのゲームAI技術の適用研究

囲碁や戦略ゲームをプレイする人工知能(ゲーム AI)について、要素技術の調査分析、先行研究の階層化技術と比較分析、階層型意思決定モデル検討、OODA 群制御 AI アーキテクチャへの適用検討を行うことを目指す。特に、時間階層化・空間階層化、ブラックボードアーキテクチャ、ゴール思考プランニング、タスクネットワーク、アテンションとシミュレーション、アフォーダンス等の概念の適用検討を行うことを目指す。また、戦略や戦術などの中長期的な意思決定の人工知能(例えば DeepMind 社の「AlphaStar」)の要素技術を調査し適用検討を行うことを目指す。

（ウ）計算力学技術によるAI軽量化の適用研究

AI 軽量化とは、学習コストや演算規模を低減することである。具体的には、機械学習モデルの入力層の手前にアダプター層を入れることで、入力データ数と入力層と中間層の一部を削減することを目指す。このアダプター層に、計算力学の空間離散化・時間差分・空間差分技術及びモデル化技術を適用することを目指す。また、階層型離散化マップによる各 OODA 機能の統合を行い、各 OODA 機能の独立性を高めパーツ化することで個々に自律化できる構造とすることで、計算規模を低減することを目指す。

● 要素課題(2)：AI信頼性向上に係わる自律アーキテクチャの研究

（ア）AIフェイルセイフ設計の適用研究：

機械学習の判断結果は、確率的であること、学習した環境変化に悪影響を受けることから、誤った判断となる可能性をゼロには出来ない。これは、故障が発生することを前提に安全性を確保することが求められる航空機のフェイルセイフ設計や損傷許容設計に通じる。AI 適用においては、自律アーキテクチャが、AI の誤判断が発生しても安全性や任務継続性を確保できるようにするフェイルセイフ設計の適用研究を行う。このフェイルセイフ設計は、同じ意思決定の過程をロジック処理と AI 処理で冗長化することを想定している。これにより未知環境における信頼性を保つことを目指す。具体的には、運用環境における学習度に応じて、学習度が少ない場合はロジックベースのシミュレーション予測制御を行い、学習度が高くなるに従い AI ベースの判断を行うことを目指す。

（イ）OODA機能毎の機械学習の適用適否の研究

各 OODA 機能について、機械学習の適用適否に関する仮説の検討研究を行う。その仮説は次の通りである。機械学習の適用良否は、学習対象の現象の時間と空間の粒度 3 と相関があり、粒度が大きいほど機械学習の有用性が高く、粒度が細かいほど現象は物理法則に支配されその有用性は低下する。粒度が細かくリアルタイム性が高い現象に機械学習を用いる場合、評価関数に物理現象の指標を用いる。その結果、機械学習とロジックベースの結果は類似したものとなり、有用性が低くなる。一方、中長期の時間粒度で現象を考慮できる場合、その評価関数に行動結果の指標を用いる場合が多くなるため、機械学習の有用性は高くなる。この仮説は、先行研究１の DQN 群協調の分析に基づいて導いた。この仮説を検証し、AI フェイルセイフ設計のアーキテクチャの研究に資することを目指す。

（ウ）学習環境の変化に対する適応的な自律アーキテクチャの研究

計算力学の空間離散化技術により、学習環境の変化への適応性を向上する研究を行う。通常、学習環境の物理現象の生データを機械学習モデルの入力層に直接エンコードする。これを、要素課題(1)(ウ)と同様に、入力層の手前にアダプター層を入れることで、学習環境の変化の影響を緩和し適応性を高めることを目指す。生データを計算力学のモデリング技術で抽象化し、空間離散化マップにプロットしたデータを入力層に入力することで適応性が向上すること目指す。なお、空間離散化マップとモデリングのイメージは、囲碁や将棋のイメージに重なる。実際の地図を碁

盤の表現形式とすることで、意思決定に必要な情報を抽象化し、不要な情報を捨象することと同義である。よって、モデリングの手法も研究対象とする。

（エ）AI判断根拠の可視化の研究

計算力学の空間離散化マップ技術による判断根拠の可視化の適用研究を行う。計算力学のモデリング技術を用いて空間離散化マップを人が認知可能なデータとして表現できるようにすることを目指す。また、それを AI の入力層の入力データに用いた場合の適用研究を行う。

（オ）実機環境に起因する問題への対応研究

機械学習は、実機環境での学習が十分でない場合、そのデジタルツインである仮想環境で学習を行う。しかし、完全に忠実なデジタルツインとして再現することは困難である。計算力学の物理現象の再現評価においても同様であるが、モデリングを適切な方法と粒度で行うことで、評価に必要な現象を再現できる。よって、機械学習においても、生データをモデリングしたものを入力層に入れることで、実機環境との差異を抑えることができることを目指す。また、実機応答遅延への対応について、UGV を対象としている遅延許容制御の UAV への適用を目指す。

２．研究開始時に設定した研究目標の達成度

２．１ 最終目標の達成度

【最終目標】本研究課題「計算力学とゲームAIを応用したOODA意思決定・群制御の研究」は、研究テーマ「未知環境において信頼構築が可能な逐次意思決定AIアーキテクチャに関する基礎研究」を踏まえ、最終目標を未知環境下においても人・無人機の組織的な意思決定と群制御を統合・自律化を可能とする、「**OODA群制御AIアーキテクチャ**に準拠したマルチエージェント制御システム**OODA群制御AIシステム**の獲得」とした。

【達成度】RCT-OODA群制御AIアーキテクチャを構築し、OODA群制御AIシステムとして汎用マルチエージェント基盤「MAARC」に要素技術を実装。中間評価では中止との評価を受けたが、その後、成果を再定義し、新規性・独創性・革新性を備えた研究成果へと発展させることに成功した。
但し、未知環境の水準が、工場での突発事象といった閉環境にとどまり、自然災害対処等の開かれた環境で実証できなかったことが残念である。

目標	達成度	コメント
OODA 群制御 AI アーキテクチャの構築	◎	RCT-OODA 群制御 AI アーキテクチャの設計・実装を完了し、CAE 技術を応用し論理・物理世界の接続に成功。
OODA 群制御 AI システムの獲得	◎	汎用マルチエージェント基盤 MAARC を実装し、シミュレーション・実機での稼働を確認。汎用性、信頼性、安全性を確認。
機能検証・性能評価・工場での突発事象	○	スマート交通シミュレーションで AI 全体最適化の有効性を確認 工場での突発事象によるリスク回避 OODA ループ自律化を実証
機能検証・性能評価・自然災害対処	×	研究中止で未達

【成果概要】これに対し、計算力学（CAE）およびゲームAI技術を融合することにより、未知環境下においても高信頼で柔軟な自律運用を可能とする新たな知能原理・アーキテクチャ・実装基盤を含むマルチエージェント技術体系を構築した。具体的には、物理的スウォーム（運動制御主体）と組織的スウォーム（意思決定主体）の二層構造を統合しうる「絵図・知識・運動系AI」を提案し、「RCT-OODA群制御AIアーキテクチャ」を設計・定義し、これを中核とした汎用マルチエージェント基盤「MAARC」を構築した。その機能検証の結果、工場搬送における異常事象検知・危険回避のOODAループ自律化の実証し、本アーキテクチャの実用性と有効性を確認した。さらには、性能評価では、スマート交通の全体の効率性最適化を評価し、輸送時間短縮（最大14.1%）を実現し、その有用性を確認した。

【中間成果の再定義】一方、本研究は、研究開始から１年弱で実施された中間評価において、「国際レベルの成果発表および新規性の提示が不十分」との指摘を受け、研究の継続は中止となった。これを受け、国際競争力の確保および研究体制の強化が課題と認識した。
その後、千葉大学および日本大学の有識者のご指導のもと、研究内容の抜本的再構成を行い、RCT-OODA群制御AIアーキテクチャを中核とする形で技術体系を再定義。その結果、新規性・独創性・革新性を備えた研究成果へと発展させることに成功した。

２.２ 要素課題の達成度

（１） 要素課題(1)：OODA 群制御 AI システムの階層型自律アーキテクチャ研究における達成度

（ア）状況適応型群制御の分析と階層型自律アーキテクチャへの移行

本研究では、RCT-OODA 群制御 AI アーキテクチャを中核とするマルチエージェント技術体系の構築に向けて、状況適応型群制御の分析と階層型自律アーキテクチャへの再設計を実施した。従来の群制御モデルを OODA ループの 4 機能（Observe, Orient, Decide, Act）に再構成し、IS-Physics 形式モデル規約に基づく階層的データモデルにより、論理世界（認知・判断）と物理世界（運動・制御）の接続構造を設計した。

その上で、MAARC（Multi-Agent AI, Robotics CPS, and CAE Platform）を用いた仮想・実機統合評価により、状況変化への適応性や、ソフトウェア分散設計の群行動の整合性を実証した。これにより、AI・制御統合アーキテクチャとしての信頼性と再構成性を備えた階層型自律群制御の有効性を確認し、本課題の目標を達成したと評価できる。

（イ）階層型自律アーキテクチャへのゲーム AI 技術の適用

OODA 群制御 AI アーキテクチャにおける階層型自律設計の高度化に向け、ゲーム AI 技術の適用研究を実施した。囲碁・戦略ゲーム AI、特に AlphaStar（DeepMind）などの先行モデルに含まれる時間・空間階層化、ゴール思考プランニング、ブラックボードアーキテクチャ、タスクネットワーク、アテンション機構、アフォーダンス理論といった要素技術を分析し、階層型 OODA ループ構造と RCT 世界モデルへの適用可能性を検討した。

特に、時間・空間階層化とブラックボードアーキテクチャ、およびタスクツリー構造を、RCT 世界モデルの状況認識・目標階層・タスク表現構造に適用することで、状況に応じた柔軟なタスク展開と意思決定の統一的記述を可能とした。

これにより、MAARC 基盤上において、中長期的戦略判断と動的群制御を接続する AI 設計の基礎を確立し、ゲーム AI の知見を活かしたマルチエージェント知能強化に貢献する成果を得た。

（ウ）計算力学技術による AI 軽量化の適用

本研究では、AI 軽量化の実現に向け、OODA 群制御 AI アーキテクチャに対し、CAE 技術（空間離散化・時間差分・モデル化技術）を応用したアダプター層の設計を検討し、階層型離散化マップとして RCT マップを導入した。これにより、構造的軽量化の基盤設計を行った。

ただし、AI 軽量化の有効性に関する評価・検証については、研究の中止により未実施となり、達成には至らなかった。今後の研究課題として継続的な検証が求められる。

（２） 要素課題(2)：AI 信頼性向上に係わる自律アーキテクチャの研究

（ア）AI フェイルセイフ設計の適用研究：

本研究における AI フェイルセイフ設計の適用研究では、AI の誤判断リスクに対応するための安全性・信頼性確保手法として、ロジック処理（ルールベース AI）と機械学習 AI の複合設計（複合 AI 設計）を導入した。具体的には、ルールベース AI による安全性担保機構をベースとしつつ、その設計パラメータを機械学習 AI により最適化することで、安全性と信頼性の両立を実現した。また、AI 判断結果の異常を検知・制限するための誤判断検知機能を、VTP(Virtual Test Platform)上に実装した。

一方で、AI の学習度に応じて判断方式をロジックベースから AI ベースへと遷移させる切替機構の実装は、研究中止により未着手となった。

（イ）OODA 機能毎の機械学習の適用適否の研究

粒度調整が可能な「RCT 世界モデル」を構築し、各 OODA 機能における情報抽象化と入力粒度の設計を実装レベルで実現した。これは、RCT-OODA 群制御 AI アーキテクチャおよび MAARC 上における、OODA 機能毎の AI 適用戦略とフェイルセイフ設計の設計基盤の一部を提示したものであり、今後の研究展開に向けた重要な理論的足場を提供するものである。しかしながら、研究の中止に

より、この仮説の定量的な評価検証には至らなかった。

（ウ）学習環境の変化に対する適応的な自律アーキテクチャの研究

本研究では、学習環境の変化に対して柔軟に適応可能な AI アーキテクチャを構築するため、CAE（計算力学）技術を応用し、空間構造や意味情報を抽象化・構造化して記述する RCT 世界モデルを構築した。このモデルは、AI の入力前処理として機能するアダプター層に相当し、実世界の物理的情報（位置、センサ、画像など）を離散化・抽象化して学習モデルに供給することで、環境変化に対する頑健性を高めることを目的としている。

本モデルは、囲碁や将棋のように盤面を抽象的に認識する構造に着想を得ており、現実の地図情報やセンサ情報を、意味階層を持った空間離散マップに変換し、意思決定に本質的な情報を抽出する仕組みである。これにより、OODA ループ各機能の入力を構造的に統合し、個々の機能を自律・独立させる設計を支援する。

これらの成果により、CAE 技術を応用した構造モデリングと抽象化によって、環境変化に頑健な認知・学習処理の基盤としての RCT 世界モデルの有効性を確認し、提案構造を実装することに成功した。ただし、研究の中断により、本構造を用いた実環境での適応性能の評価や学習効率への効果の検証には至らなかった。本成果は、今後の適応型 AI アーキテクチャ研究の基盤となるものである。

（エ）AI 判断根拠の可視化の研究

本研究では、CAE（計算力学）技術に基づく空間離散化マップを応用し、AI の判断根拠を可視化可能な RCT 世界モデルを構築した。RCT 世界モデルは、空間・構造・意味の 3 層を持つ形式記述により、AI がどの状況下で、どのようなリスク・コスト・目標をもとに判断を行ったかを構造的に示すことができる。

この可視化モデルは、AI の入力層と連動させることで、判断過程の透明性や説明可能性（Explainability）を高め、未知環境下でも人が AI の動作理由を検証できる設計とした。

なお、本モデルの運用評価や人による解釈可能性の検証は、研究中止により未実施である。

（オ）実機環境に起因する問題への対応研究

本研究では、実機環境と仮想環境との間に生じる応答ギャップ（Sim2Real ギャップ）に対し、リアルタイムで把握・対応可能なデジタルツイン環境を構築した。具体的には、MAARC の VTP（Virtual Test Platform）において、仮想エージェント、実機エージェント間の挙動差異をリアルタイムで可視化・評価できる機能を実装した。また、遅延許容制御をルールベース AI 実装し、仮想エージェントと実機エージェントの間に動作差異があっても、安全に群制御が可能であることを実環境にて実証した。

しかし、機械学習系 AI を用いた本格的な適応制御の適用と検証に入る前に、本研究は中止となったため、実証は未達である。

３．委託業務における研究の方法及び成果

本項の構成を以下に示す。
はじめに研究全体の総括を示す。ここでは、各実施項目の成果のうち、本研究課題に直接関係し、新規性・独創性・革新性の高い内容をまとめている。
続いて、各実施項目について報告する。ここでは、総括で示した成果を獲得するために実施した設計や実装について報告している。

【本項の構成】

（全体総括）	関連実施項目：
３．１　成果総括	
３．１．１　総括概要	
３．１．２　主要成果	
３．１．２．１　課題深堀と本質的構造：二層構造スウォーム統合の課題	（実①）
３．１．２．２　マルチエージェント技術体系の構築	（実①）
３．１．２．３　新知能原理「絵図・知識・運動系 AI」の提案	（実①）
３．１．２．４　RCT-OODA 群制御 AI アーキテクチャの構築	（実①）
３．１．２．５　OODA 群制御 AI(意思決定・群制御の統合知能)の構築	（実①②③）
３．１．２．６　RCT 世界モデル(AI 認知思考制御基盤)の構築	（実①②③）
３．１．２．７　IS-Physics 形式モデル規約(知能と物理の統合表現仕様)の構築	（実①④）
３．１．２．８　MAARC(汎用マルチエージェント基盤)の構築	（実①④⑤⑥）
３．１．２．９　新 AI アーキテクチャの機能実証・性能評価	（実①④⑤⑥）
３．１．２．１０　結言：新規性・独創性・革新性のポイント	
３．１．３　本研究の位置付けと成果の自己評価	
３．１．３．１　本研究内容の学問領域における位置付け	
３．１．３．２　本研究内容の新規性、独創性、及び革新性	
３．１．３．３　既存研究に対する優位性	
３．１．４　本研究に関する関連用語および略語	

（各実施項目報告）	関連主要成果：
３．２　実施項目①OODA 群制御 AI アーキテクチャの研究	課題深堀：二層構造スウォーム 絵図・知識・運動系 AI 知能原理 RCT-OODA 群制御 AI アーキテクチャ OODA 群制御 AI RCT 世界モデル IS-Physics 形式モデル規約
３．３　実施項目②AI ソルバの構築	OODA 群制御 AI
３．４　実施項目③ロジックソルバの構築	OODA 群制御 AI
３．５　実施項目④OODA 群制御 AI システムの構築と試験実施	MAARC ACS
３．６　実施項目⑤仮想テスト環境の構築と試験実施	MAARC VTP
３．７　実施項目⑥実機テスト環境の構築と試験実施	MAARC-外部システム

３．１　成果総括

３．１．１ 総括概要

【最終目標】本研究課題「**計算力学とゲーム AI を応用した OODA 意思決定・群制御**の研究」は、研究テーマ「**未知環境**において**信頼構築**が可能な**逐次意思決定** AI アーキテクチャに関する基礎研究」を踏まえ、最終目標を未知環境下においても**人・無人機の組織的な意思決定と群制御を統合・自律化**を可能とする、**AI アーキテクチャとマルチエージェント制御システムの構築**とした。

【成果概要】これに対し、**計算力学（CAE）**および**ゲーム AI** 技術を融合することにより、未知環境下においても高信頼で柔軟な自律運用を可能とする新たな**知能原理・アーキテクチャ・実装基盤**を構築した(図　３．１．１－１参照)。具体的には、**物理的スウォーム（運動制御主体）**と**組織的スウォーム（意思決定主体）**の二層構造を統合しうる「**RCT-OODA 群制御 AI アーキテクチャ**」(図　３．１．１－２参照)を設計・定義し、これを中核とした**汎用マルチエージェント基盤「MAARC」**を構築した(図　３．１．１－３参照)。その機能検証・性能評価結果(図　３．１．１－４参照)を示す。機能検証は、**工場搬送**における**異常事象検知・危険回避の OODA ループ自律化の実証**、本アーキテクチャの実用性と有効性を確認した。性能評価は、**スマート交通の全体の効率性最適化**を評価し、輸送時間短縮（最大 14.1%）を実現し、その有用性を確認した。

【中間成果の再定義】一方、本研究は、研究開始から１年弱で実施された中間評価において、「**国際レベルの成果発表および新規性の提示が不十分**」との指摘を受け、**研究の継続は中止**となった。これを受け、**国際競争力の確保および研究体制の強化**が課題と認識した。

その後、**千葉大学　荒井幸代先生および日本大学　古市昌一先生**のご指導のもと、研究内容の抜本的再構成を行い、**RCT-OODA 群制御 AI アーキテクチャを中核とする形で技術体系を**再定義。その結果、**新規性・独創性・革新性を備えた研究成果へと発展**させることに成功した。

これら一連の成果を、着手から１年５か月という限られた期間内に実現できたことは、ご指導いただいた有識者の先生方の多大なるご助力と、本研究チームメンバの不断の努力の賜物であり、研究代表者として深く謝意を表するものである。

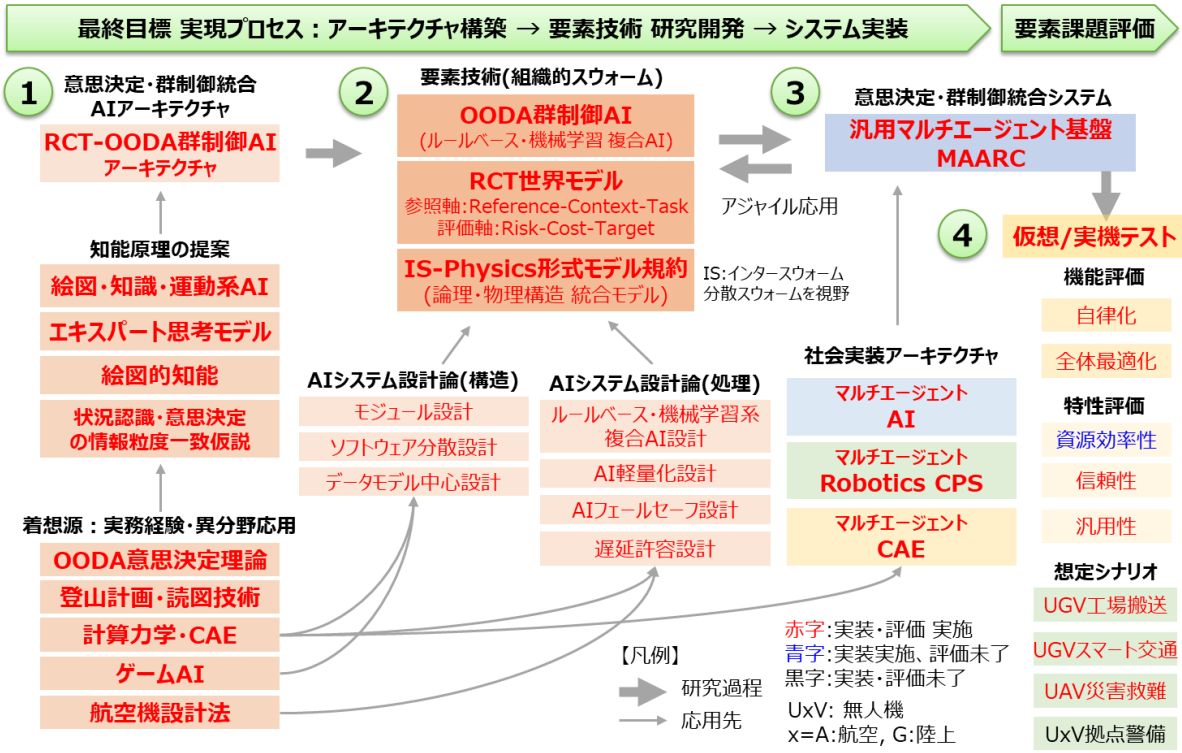

図　３．１．１－１　マルチエージェント技術体系の構築過程概念モデル

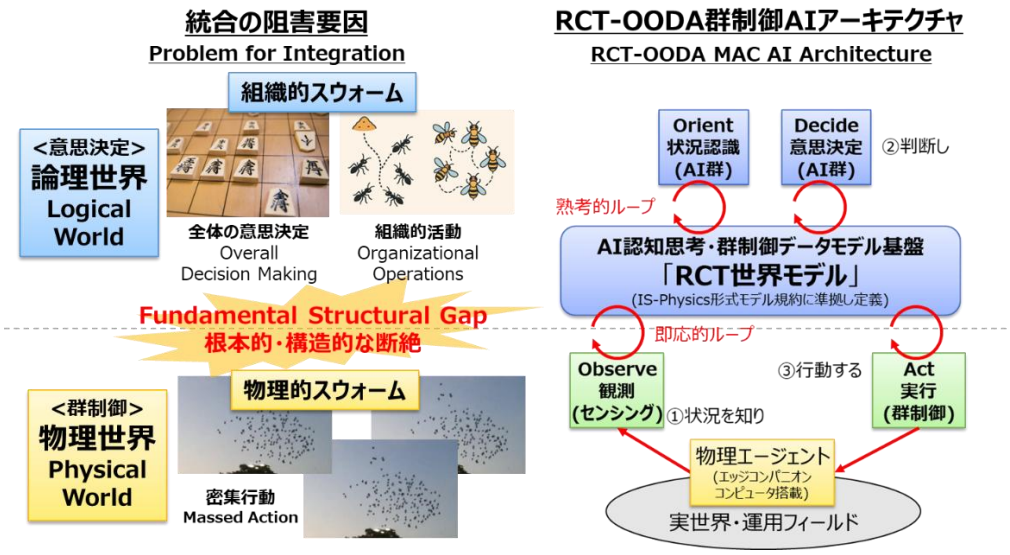

図　３．１．１－２　RCT-OODA 群制御 AI アーキテクチャの構築

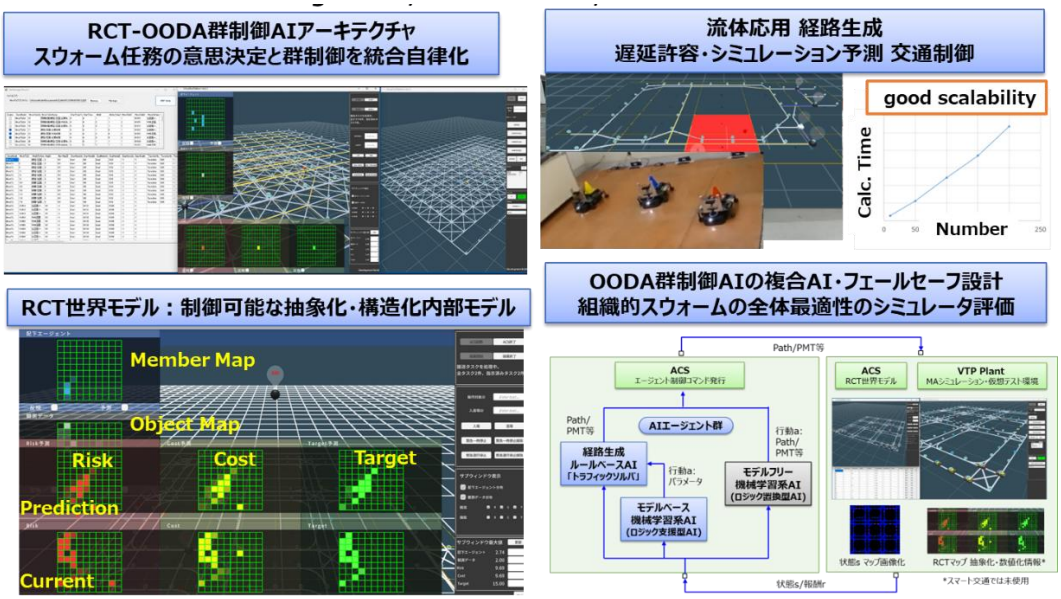

図　３．１．１－３　汎用マルチエージェント基盤 MAARC への実装

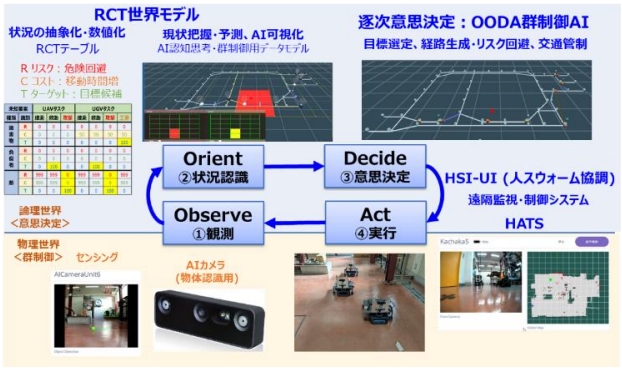

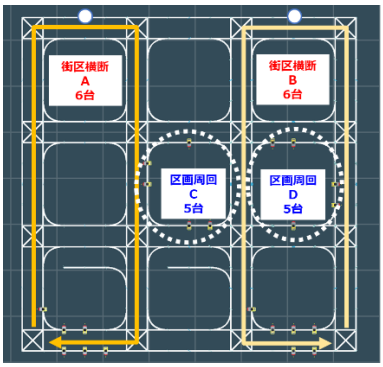

任務種類	チーム	台数	タスク数
街区横断	A	6台	54
	B	6台	54
区画周回	C	5台	140
	D	5台	140

経路生成方式	AI構成	全タスク分割（ステップ数）	輸送送時間 秒（比率）	備考
移動時間最小化	ルールベース	分割なし	498.7 (100)	基準
Path基準混雑考慮経路生成	ルールベース	分割なし	478.6 (95.9)	
	ロジック支援型	2分割	485.3 (97.3)	
		3分割	463.5 (92.9)	効果あり
Area基準混雑考慮経路生成	ルールベース	分割なし	428.4 (90.2)	
	ロジック支援型	2分割	426.7 (89.9)	効果あり
		3分割	407.8 (85.9)	効果あり

(a)危険回避 OODA ループ自律化実機検証　　(b)スマート交通　輸送効率全体最適化

図　３．１．１－４　RCT-OODA 群制御 AI アーキテクチャ　機能検証・性能評価

３．１．２ 主要成果

３．１．２．１ 課題深堀と本質的構造：二層構造スウォーム統合の課題

本研究対象の**無人機群運用の自律化**(図 ３．１．２－１参照)は、図 ３．１．２－２に示すスウォームの二層構造を考慮する必要がある。これら二層のスウォームは、表 ３．１．２－１に示すように、**動作特性・情報構造・制御様式のすべてにおいて根本的な違い**を有している。

課題の本質は、**「物理的スウォームと組織的スウォーム」**、即ち、**「意思決定と群制御」、「論理世界と物理世界」の階層間の根本的構造的な断絶を、如何に統合するか**をという研究的質問に答えることが不可欠であり、構造的かつ本質的な技術的挑戦にある(図 ３．１．２－３参照)。

図 ３．１．２－１ マルチエージェント技術の応用先と技術要求の想定

図 ３．１．２－２ 無人機群運用におけるスウォームの２層構造

表 ３．１．２－１ 二層スウォームの特徴

観点	組織的スウォーム	物理的スウォーム
領域	仮想空間（情報・意思決定）	実世界（空間・動力学）
時間スケール	秒～分単位の状況認識・戦術的な意思決定	ミリ秒～秒単位のリアルタイム制御
情報形式	状況評価、目標階層、役割情報	座標、速度、センサデータ
抽象度	高（意味構造に基づく論理情報）	低（物理座標ベース）
制御様式	分散知能、状況駆動、ミッションドリブン制御	フィードバック制御、近接通信

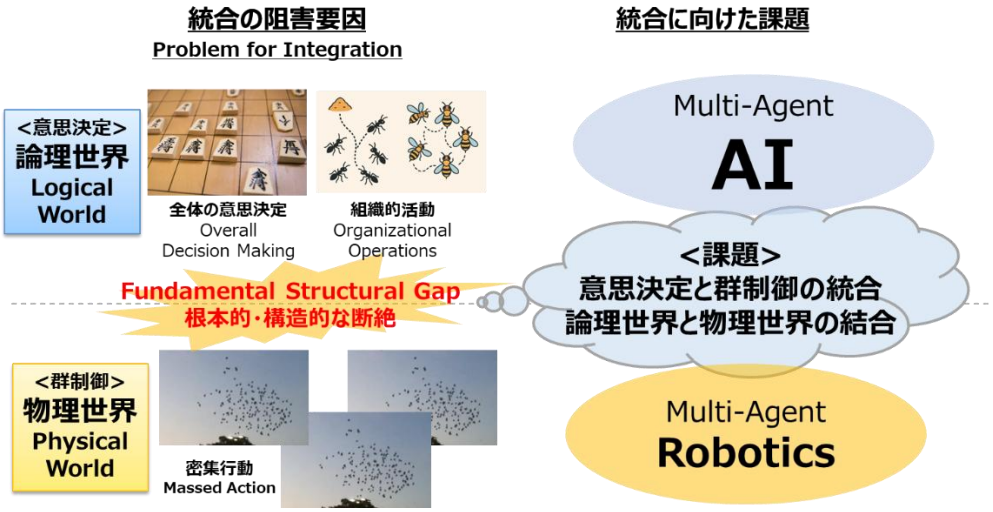

図　３．１．２-３　意思決定と群制御の統合に向けた課題

３．１．２．２ マルチエージェント技術体系の構築

（１）　技術体系の概要

本研究では、**知能原理・アーキテクチャ・設計論・要素技術・システム実装・社会実装手法**を一体化した「**マルチエージェント技術体系**」を提案し、防災・警備・物流・交通など多分野への応用展開を見据えた**汎用性・再利用性・進化性のある構造**として整備した。

本技術体系は、分散協調的な任務運用に対応するため、ソフトウェア分散・データモデル中心設計を適用した RCT-OODA 群制御 AI アーキテクチャが中核となる。

即ち、技術体系は、分散協調的なマルチエージェントによる**観測・認識・意思決定・行動**を支える統合技術枠組みであり、原理から運用まで一貫性を持つ点に本質的な特徴がある。

（２）　中核となる 2 つの概念アーキテクチャ

（ア）意思決定・群制御統合「RCT-OODA 群制御 AI アーキテクチャ」

- **知能原理：** 専門家の思考法と OODA 意思決定理論を参考に「状況認識」と「意思決定」の構造を分離し、身体性を付与した「絵図・知識・運動系 AI」知能原理に基づく。
- **技術基盤：** 絵図的知能と CAE（計算力学）技術を融合し、抽象構造の可視化・定量化を実現。二重過程モデルの世界モデルに対して、制御性、透明性を付与し、AI 信頼性を向上。
- **構成：**
  - OODA ループ（Observe-Orient-Decide-Act）の統合制御
  - ソフトウェア分散型 AI モジュール群による自律・協調的判断・行動
  - 制御・可視化可能な RCT 世界モデルによる AI モジュール群の自律協調

（イ）社会実装「MAARC 三位一体」アーキテクチャ

MAARC(Multi-Agent AI, Robotics CPS, and CAE)三位一体 AI アーキテクチャは、RCT-OODA アーキテクチャを社会実装可能するためのプラットフォームとアプローチを構造化したものである(図　３．１．２-６、図　３．１．２-７参照)。以下の３つの基盤機能で構成される：

- **① マルチエージェント AI（認知・判断統合）**
  - OODA 群制御 AI＋RCT 世界モデル
  - ソフトウェア分散・データモデル中心設計による協調的知能制御
- **② マルチエージェント Robotics CPS（身体性の実装）**
  - UAV/UGV 等の物理エージェントによるリアルタイム分散制御
  - 通信遅延許容制御、信頼性・安全性・スケーラビリティを実現

- ③ マルチエージェント CAE（任務設計・全体最適化）
  - 任務モデル・行動計画・最適化を一体化
  - 専門的判断の抽象化・可視化・検証に基づいた AI 設計支援

（３） 社会実装アーキテクチャとしての意義

- **技術と運用を橋渡しする一貫構造**として、設計から現場運用まで接続可能
- **適応性・拡張性・再利用性**に優れ、防災・警備・物流・交通等における**持続可能な省人化・高度化**を実現
- **シミュレーションと実機試験の両立**により、**信頼性・安全性・効率性**を担保した AI 社会実装を支援

このように、本研究では、**理論・設計・実装・運用**を一貫した構造で統合し、**技術整合性と社会応用性を両立**するマルチエージェント技術体系を確立した。

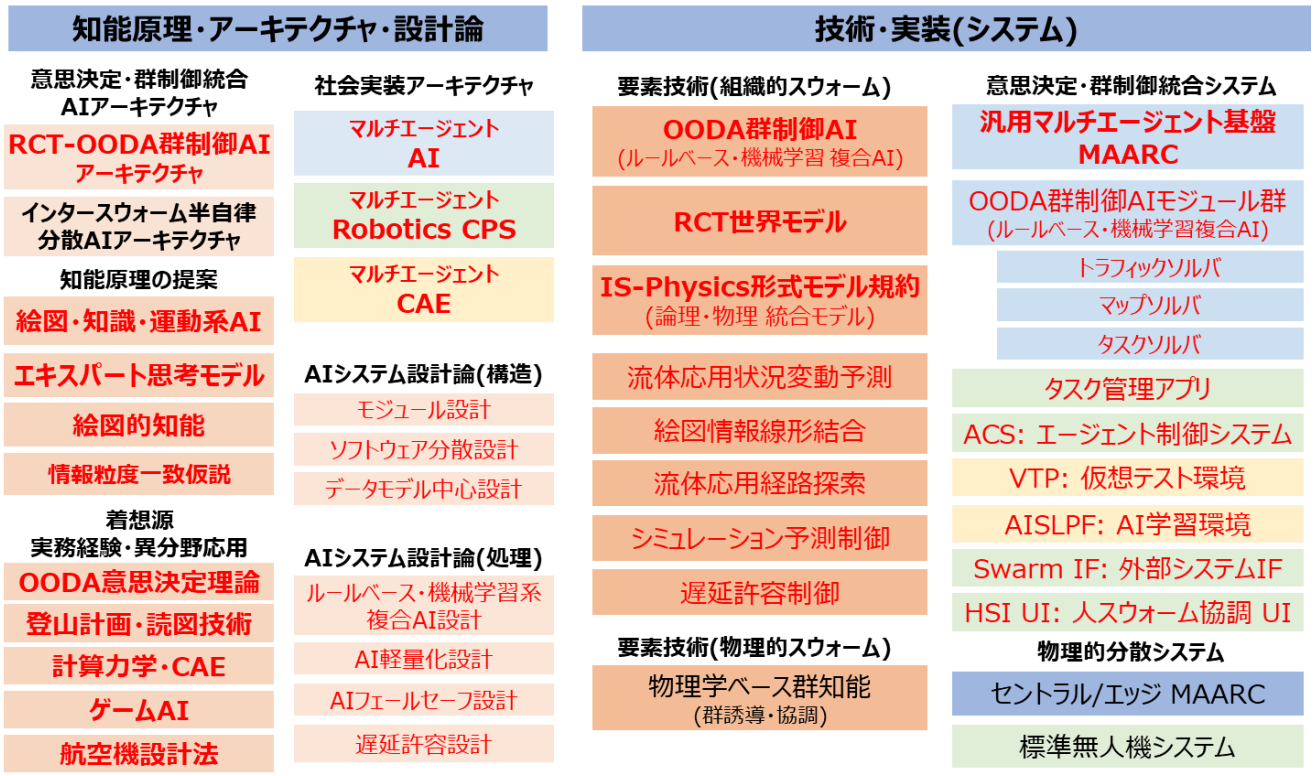

図 ３．１．２－４ 無人機マルチエージェント技術体系（赤字が本研究の成果）

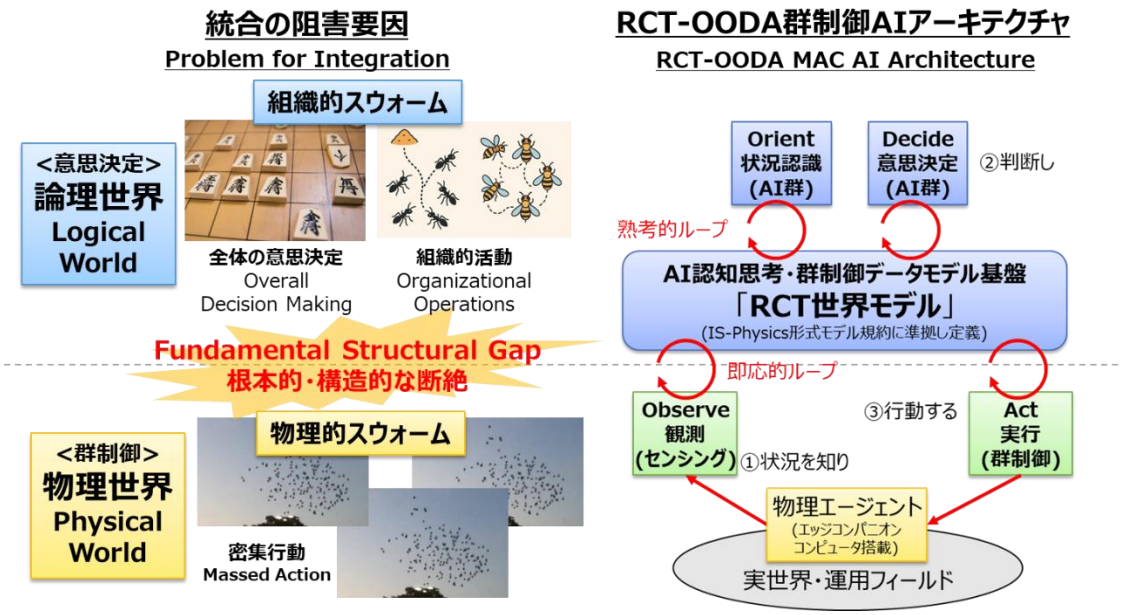

図　３．１．２－５　意思決定・群制御統合「RCT-OODA 群制御 AI アーキテクチャ」概念図

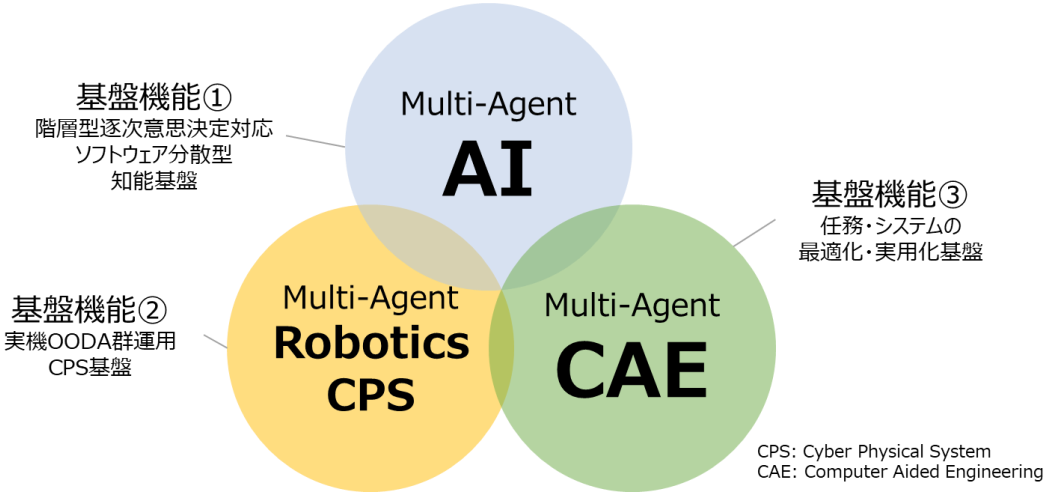

図　３．１．２－６　MAARC 三位一体アーキテクチャの概念図

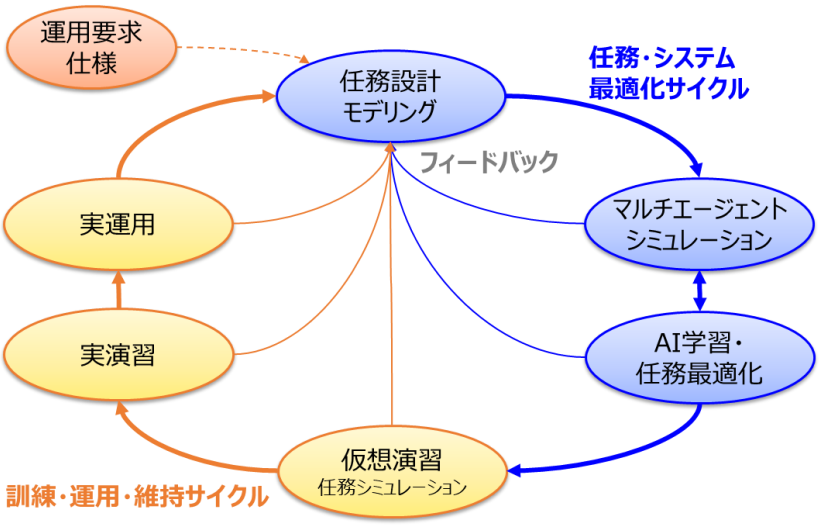

図　３．１．２－７　MAARC 三位一体アーキテクチャによる社会実装モデル

表 ３．１．２-２　原理・設計論 用語一覧

用語	定義
絵図・知識・運動系 AI	図的知識(絵図)、意味構造(知識)、制御(運動)を統合する新しい知能原理
エキスパート思考モデル	専門家の意思決定・状況理解の過程をモデル化したもの
絵図的知能	図解・絵図を使って構造や状況を把握・推論する知能。
情報粒度一致仮説	AI が知覚・理解・判断を行う際、情報の抽象度（粒度）が一致していることが有効な認知判断につながるという仮説
OODA 意思決定理論	Observe-Orient-Decide-Act（観察-状況判断-意思決定-行動）の 4 段階からなる意思決定フレームワーク
計算力学・CAE	物理現象を数値解析により再現・予測する工学技術。構造解析、流体解析などを含む。
航空機設計法	航空工学に基づいた設計理論。
登山計画・読図技術	空間認識・経路選定・リスク判断を含む総合的な認知行動計画
マルチエージェント AI	複数の AI エージェントが協調・分担して意思決定・行動を行うシステム
マルチエージェント Robotics CPS	物理ロボットを含むサイバーフィジカルシステム。制御・センサ・通信が統合された実世界対応型マルチエージェント
マルチエージェント CAE	機械工学の CAE のマルチエージェント版
モジュール設計	機能を独立したモジュールとして分離し、再利用性と保守性を高めた設計方式
ソフトウェア分散設計	機能を複数モジュールに分解し、全体として協調するソフトウェア設計方式
データモデル中心設計	データ構造を中心に機能間の連携を設計する方式。柔軟な拡張性を確保できる。
AI コンポジット設計 (AI 複合設計)	複数の AI モデル(ルールベース、機械学習等)を組み合わせる設計手法
AI 軽量化設計	学習や推論の計算負荷を低減する設計手法
AI フェイルセイフ設計	AI が誤判断した際にも、安全性や最小限の機能を保つよう設計する手法
遅延許容設計	通信や応答遅延が内在しても、安全性を保つよう制御設計する手法

表 ３．１．２-３　原理・設計論 用語一覧

用語	定義
RCT-OODA 群制御 AI アーキテクチャ	専門家の思考様式と絵図的知能の概念に着想を得て開発された次世代 AI アーキテクチャ
OODA 群制御 AI	OODA 意思決定理論を応用した階層型逐次意思決定・群制御 AI
RCT 世界モデル	AI の認知思考・群制御用の内部モデル
IS-Physics 形式モデル規約	空間・構造・任務を統一的に記述するための形式。
流体応用経路探索	流体法則を応用した経路探索を実現する手法。
シミュレーション予測制御	事前に予測制御を行う群制御手法。
遅延許容制御	通信・処理遅延下でも群の動作整合性を維持する制御技術。
物理学ベース群知能	物理法則を応用して制御する群知能設計。
MAARC	汎用マルチエージェント基盤ソフトウェア
トラフィックソルバ	経路生成と衝突回避トラフィック制御を行う。
マップソルバ	観測情報を状況分析・変化予測を行う。
タスクソルバ	任務や作業割り当て調整を行う AI 機能。
タスク管理アプリ	現場でのタスク実行や進捗状況の角煮を
ACS	エージェント制御システム。AI の判断を無人機に伝える。
VTP	シミュレータ、リアルタイムデジタルツイン、局所群制御を担う。
AILPF（AI 学習環境）	AI の学習（模倣・強化学習）を支援する実験環境。
Swarm IF	MAARC と実機・他システムとの接続インターフェース。
HSI UI	人スウォーム協調を支援する直感的低負荷 UI。
インタースウォーム 半自律分散 AI アーキテクチャ	数スウォーム間の協調を可能にする自律性と分散性を併せ持つ AI 構造。
インタースウォーム 半自律 OODA 群運用基盤	AI と人間の協調によるスウォーム運用基盤。分散・OODA・半自律の統合設計。
インタースウォーム対応 無人機システム	上記運用基盤を適用した、実際の無人機（UAV/UGV 等）ハードウェア群。

３．１．２．３ 新知能原理「絵図・知識・運動系AI」の提案

本項では、RCT-OODA 群制御 AI アーキテクチャの思想的出発点となった「**絵図的知能**」に基づき、新たな知能原理として「**絵図・知識・運動系 AI**」を提案する。これは、既存の AI 原理を補完・統合しうる新しい枠組みであり、今後の AI 設計における理論的柱として展開することを目指している。

（１） 「絵図・知識・運動系 AI」の定義と背景

「絵図・知識・運動系 AI」は、**実務経験を持つ専門家の思考様式**(図 ３．１．２－８参照)に基づいた AI 設計原理である。特に、図的な構造表現「絵図」を用いて、知識の可視化と空間的把握を可能とする。以下のような特徴を持つ「**絵図的知能**」に着想を得ている：

- 観察対象の**構造や関係性**を絵図として表現
- 絵図を通じて**状況の全体像や変化予測**を把握
- 絵図に基づき**判断と行動計画**を一体的に行う

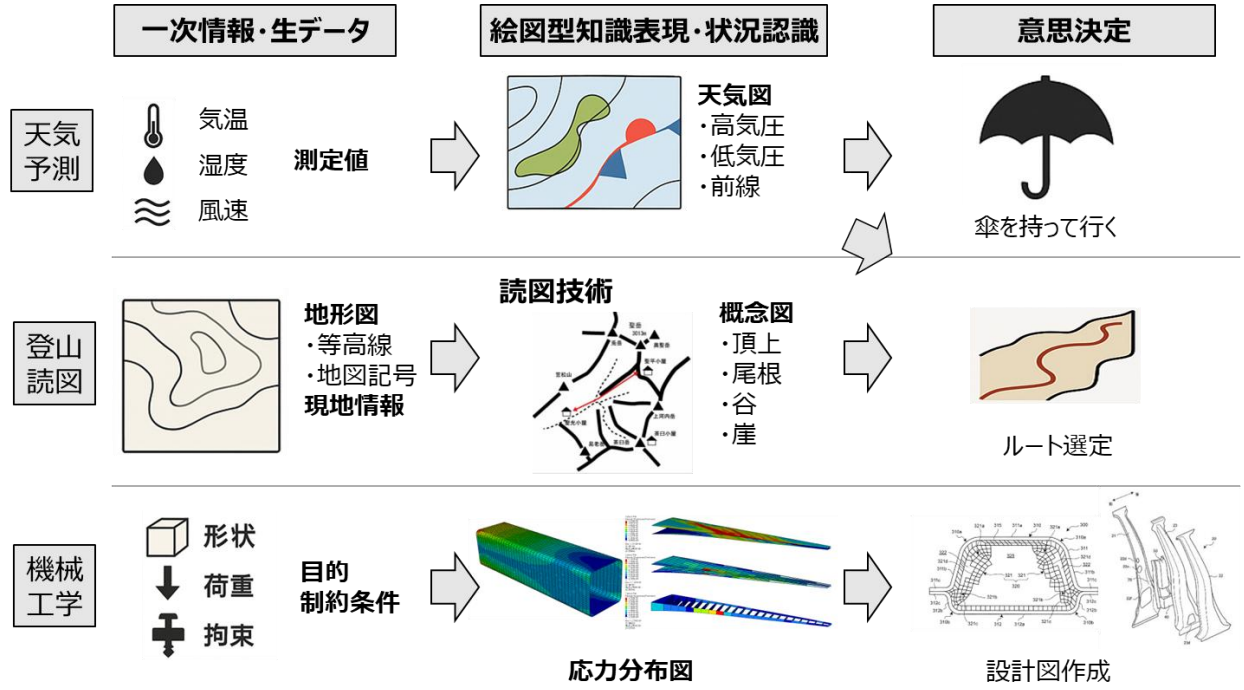

図 ３．１．２－８ 実務経験に基づく専門家の思考様式・絵図的知能

（２） 他の AI との違いと統合的特性

「絵図・知識・運動系 AI」は、従来の AI が分担してきた知覚・運動処理と知識・言語処理という二つの知能機能を、**絵図という空間的・構造的表現**を用いて統合する新たなアプローチである(表 ３．１．２－４、表 ３．１．２－５参照)。

従来の**知覚・運動系 AI** は、主にセンサ入力に基づいて物理空間における行動を制御する AI であり、ロボティクスや制御系に適用されてきた。一方で、**自然言語・知識系 AI** は、テキストや論理記述といった記号的表現を用いて、推論や知識処理、対話生成などの機能を担ってきた。これらはそれぞれに特化して発展してきたが、相互の連携には限界があり、**構造理解や行動計画における一貫性の欠如**が課題となっていた。

これに対し、「絵図・知識・運動系 AI」は、**専門家が頭の中で用いている「図的な思考操作」に着目し、知識と運動の間を橋渡しする中間表現**として「絵図」を導入する。絵図は、対象の空間構造や因果関係、行動パターンなどを一望的・直感的に把握する手段であり、**構造理解（どのようになっているか）、状況認識（いまどうなっているか）、行動計画（どうすべきか）を一体として処理**できる。

このように本知能原理は、知覚・運動系 AI と知識・言語系 AI の**それぞれの長所を活かしつつ統合**し、現実世界での認知・判断・行動の一貫性と柔軟性を実現するための基盤となる。特に、

現場での判断や応用に強い「実践的知能」の獲得に向けた重要な進展であると位置付けられる。

表　３．１．２－４　各知能原理の比較：着想源と課題解決の観点から

知能原理の種類		①知覚・運動系AI	②自然言語・知識系AI	③絵図・知識・運動系AI
理論的な基礎		システム１ 即応的ループ	システム２ 熟考的ループ	OODAループ (観測・状況認識・意思決定・行動)
着想源		人間の脳情報処理・ 認知発達過程	人間の脳情報処理・ 認知発達過程	専門家の思考法 絵図的知能
知識表現形式		画像・動画・音声	自然言語	絵図
AIの種類		帰納型・機械学習	帰納型・機械学習	帰納型・演繹型 併用
AI 本質的 課題	資源効率性	× 大量のデータ・計算資源	× 大量のデータ・計算資源	○ ソフトウェア分散設計・RCT世界モデル
	身体性	○ ロボット制御・自動運転	× 原理的にNG	○ RCT-OODA群制御AIアーキテクチャ
	論理性	× タスク分解・論理演算NG	○ 生成AI・対話AI	○ エキスパート思考モデル IS-Physics形式モデル規約
	信頼性	× ブラックボックス性、確率的判断	× ブラックボックス性、確率的判断	○ RCT世界モデルの判断材料可視化
	安全性	× 確率的判断	× 確率的判断	○ AIフェールセーフ設計、AI誤判断検知 ルールベース支援機械学習AI
社会 実装 課題	汎用性	× 専用化している	○ 生成AI・対話AI	○ IS-Physics形式モデル規約 ○ 未知領域はルールベースで先行対応
	進化性・拡張性	× 専用化している	△ 継続的な学習	○ ソフトウェア分散・データモデル中心設計
	相互運用性	× 専用化している	△ 継続的な学習	○ IS-Physics形式モデル規約
①②統合アーキテクチャ		２重過程理論AIモデル		RCT-OODA群制御AIアーキテクチャ

表　３．１．２－５　各知能原理の比較：知識・知能・身体性の観点から

知能原理の種類		①知覚・運動系	②自然言語・知識系	③絵図・知識・運動系
知識	表現形式	視覚 (写真・動画)	自然言語 (用語・文法)	絵図 (状態図・地図等)
	専門性	一般的	一般的	専門的
	所在	公開・データ多い	公開・データ多い	偏在・サイロ化
知能	認知	画像認識AI	大規模言語モデル 対話AI等	①②の統合 ↓ RCT世界モデル ・ OODA群制御AI
	思考	囲碁・将棋・戦略ゲーム AI		
身体性	制御	ロボット制御 自動運転等	–	

（３）　エキスパート思考モデルとしての実装

「絵図・知識・運動系 AI」は、専門家の思考様式を模倣・形式化した**エキスパート思考モデル**（図　３．１．２－９）として実装される。本モデルでは、専門家が実務現場で行う「観察・理解・判断・行動」の一連の過程を、**絵図を基盤とする情報表現と操作体系**として再構成する。

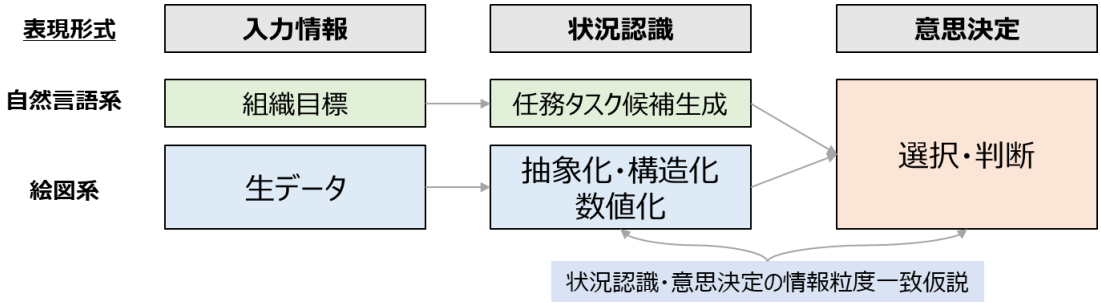

図　３．１．２－９　エキスパート思考モデルの構成

３．１．２．４ RCT-OODA群制御AIアーキテクチャの構築

RCT-OODA 群制御 AI アーキテクチャは、専門家の思考様式と「絵図的知能」の概念に着想を得て開発された次世代型の AI アーキテクチャである。本アーキテクチャは、意思決定と運動制御を統合する OODA ループ（Observe-Orient-Decide-Act）理論を基盤とし、さらに計算力学（CAE）やゲーム AI 技術を融合することで、汎用性と柔軟性、実装可能性を兼ね備えた構造となっている（図 ３．１．２－１０参照）。また、逐次的意思決定と群制御の知的機能を、絵図的な内部モデルと CAE 的構造抽象化を用いて一体的に設計・運用可能とする点において、実践性・汎用性・拡張性に優れた AI アーキテクチャである。

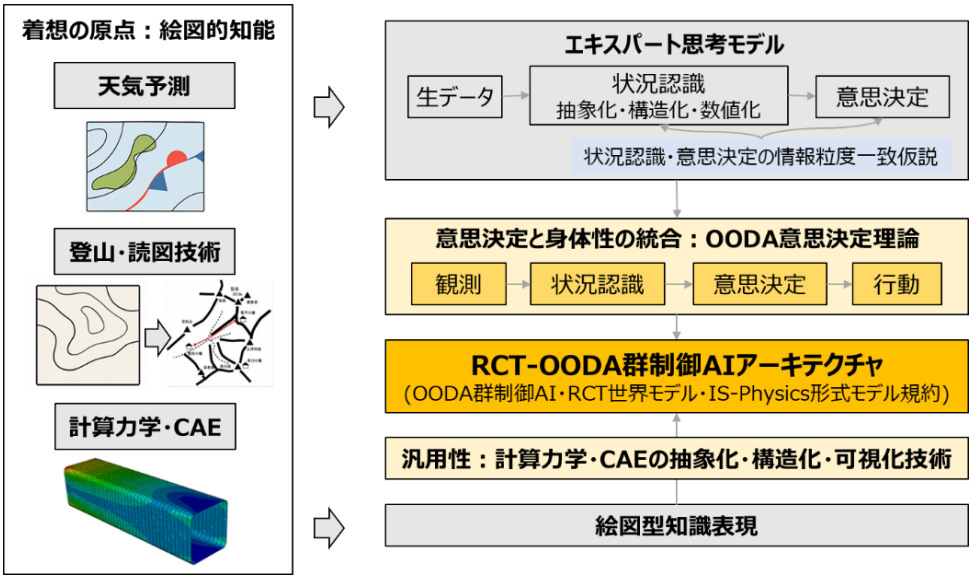

図 ３．１．２－１０ RCT-OODA 群制御 AI アーキテクチャの着想

次に、本アーキテクチャは心理学における二重過程理論 AI と対比される（図 ３．１．２－１１参照）。二重過程理論は、人間の思考を「直感的・高速なシステム 1」と「熟慮的・論理的なシステム 2」の２つのモードに分け、その交互作用により意思決定がなされるという内面的モデルに基づく。一方、RCT-OODA 群制御 AI は、人間の内面を模倣するのではなく、**外在化された構造（絵図）としての認知モデル**を用いて、複数エージェント間の共通理解と意思決定の整合性を確保する。これにより、実環境下において視認性と操作性の高い「構造知能」が実現される。

これに対し、RCT-OODA 群制御 AI アーキテクチャは、着想の点において、従来の AI モデルとは異なり、専門家が暗黙的に行っている構造的思考や判断の勘所をエキスパート思考モデルとして捉え直すものである。人間が外界を把握し、状況を構造として認識・再構成するプロセスを「絵図的知能」として抽象化し、この絵図を中核モデル（RCT 世界モデル）として AI に実装する。これにより、AI は単なるデータ処理ではなく、構造的な意味理解と状況適応的判断を実行可能となる。さらに、絵図に基づいた認知・判断・行動の統合プロセスを OODA ループとして表現することで、逐次的かつ動的な意思決定を支援する。

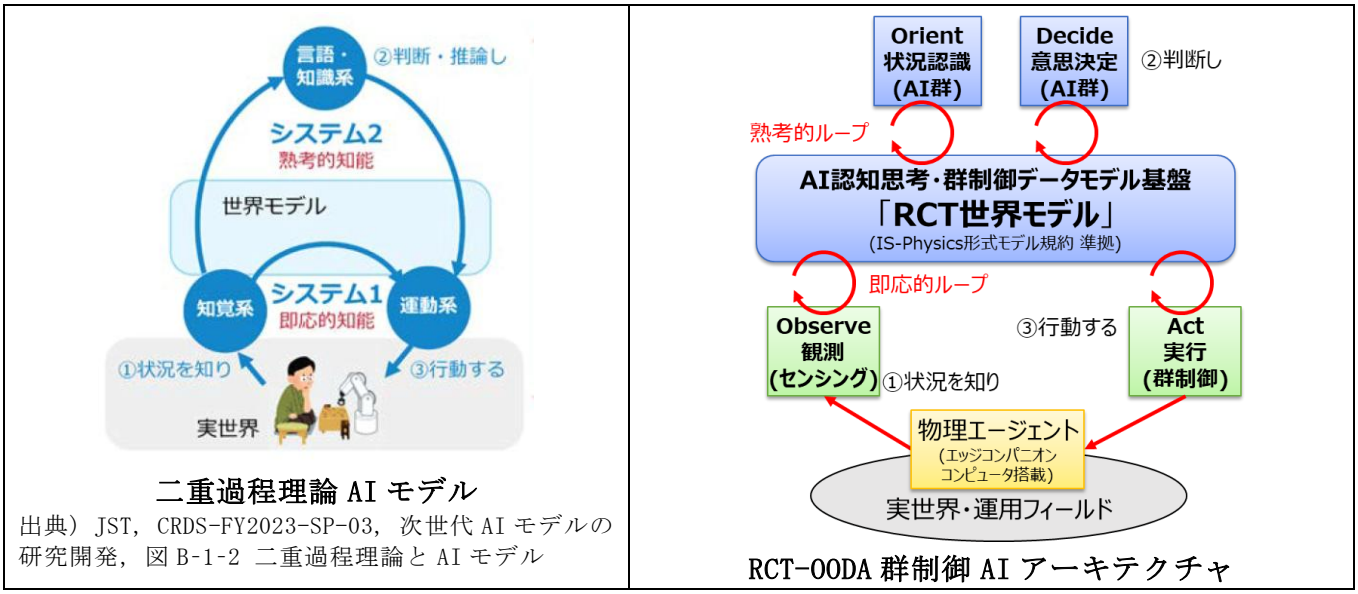

図　３．１．２－１１　意思決定と制御を統合・自律化に向けたアーキテクチャ比較

３．１．２．５ OODA群制御AI（意思決定・群制御の統合知能）の構築

OODA 群制御 AI は、マルチエージェントにおける意思決定および群制御の自律化・統合化を目的とした AI モジュール群であり、観測（Observe）・状況認識（Orient）・意思決定（Decide）・行動（Act）の各段階を、**機能分解・モジュール設計**に基づいて構築している（図　３．１．２－１２参照）。本 AI は、各機能を独立した AI モジュールとして実装し、それらを**ソフトウェア分散設計**により疎結合・高協調的に構成することで、冗長性と拡張性に優れた群制御基盤を形成している。

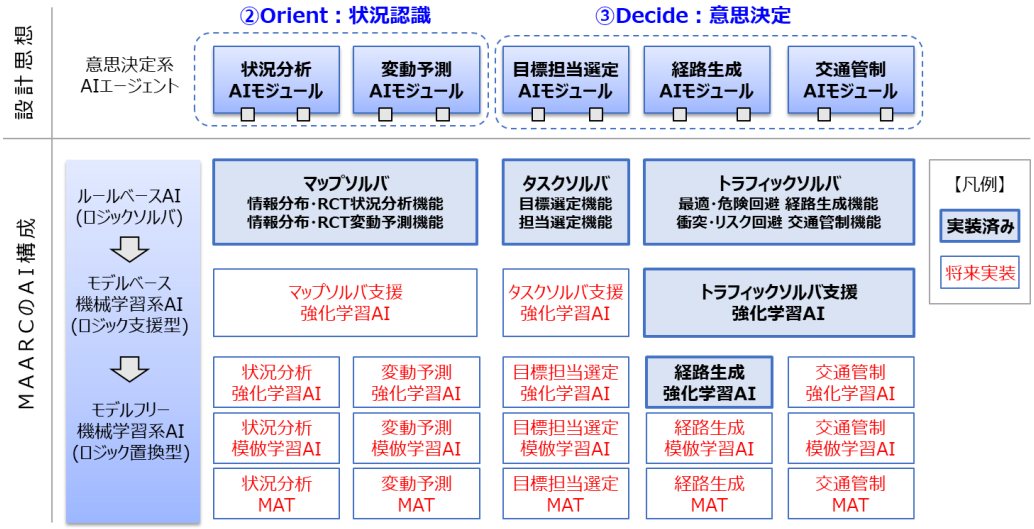

図　３．１．２－１２　ソフトウェア分散設計の OODA 群制御 AI のモジュール構成

３．１．２．６ RCT世界モデル（AI認知思考制御基盤）の構築

本研究で提案する RCT 世界モデルは、**実世界に存在する多様な情報を抽象化・構造化・数値化し、AI エージェントおよび人間の双方による状況認識、意思決定、群制御を統合的に支援する認知・情報共有基盤**である（図　３．１．２－１３参照）。本モデルは、CAE（Computer-Aided Engineering）およびゲーム AI 技術に基づく IS-Physics 形式モデル規約に準拠して利用者が構築し、抽象度や粒度の調整可能性を特徴とする柔軟な情報構造を備えている。

「RCT」は、本モデルにおける情報の設計・解釈・活用における主要な参照枠組みを示しており、二つの評価軸から構成される。第一の軸は、**参照軸（Reference, Context, Task）**であり、対象情報が置かれる基準、文脈、およびタスクとの関係性を明示化することで、情報の意味的安定性と場面適応性を高める。第二の軸は、**評価軸（Risk, Cost, Target）**であり、行動選択や戦術判断において重要となる目標指向性、コスト制約、およびリスク評価の構造を与える。

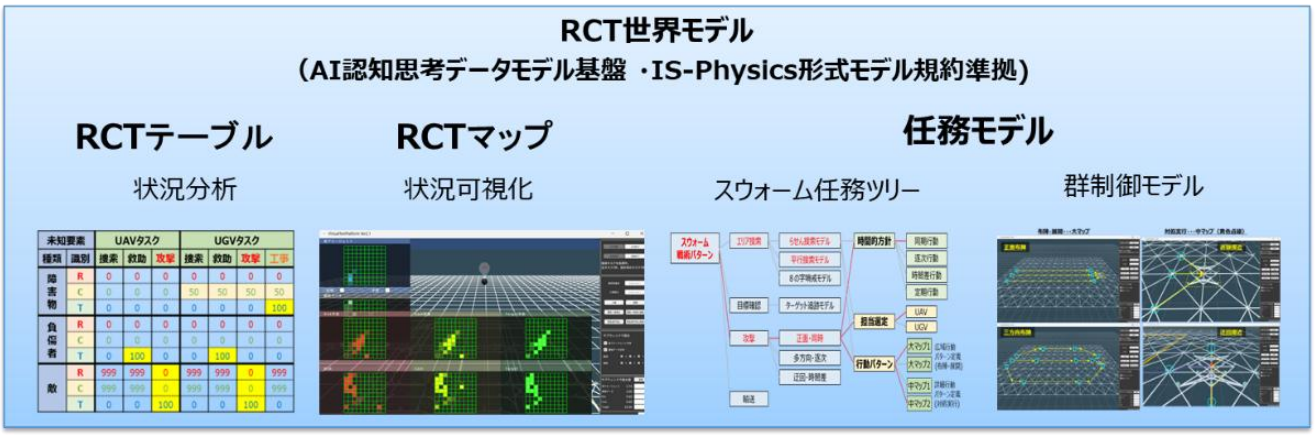

図　３．１．２－１３　RCT 世界モデルの構成

３．１．２．７ IS-Physics形式モデル規約（知能と物理の統合表現仕様）の構築

背景と目的：現実のロボティクス・マルチエージェント環境においては、図　３．１．２－１４に示すように AI が物理的実体をもって空間内で行動することが前提であり、多体動力学的な空間認知能力と実体的な身体性が不可欠である。AI は論理的な推論だけでなく、現実空間における構造や制約を理解・対応しなければならない。

本研究における中心的な問いは、「資源効率と信頼性を両立しつつ、AI に身体性を持たせるには、どのようなアーキテクチャが必要か」という点にある。その解決のためには、物理や空間に関する状況認識・意思決定プロセスをモデル化し、論理世界と接続する手法が必要である。

この課題に対し、本規約は、専門家の思考法と知識表現（言語と絵図）を基盤に、OODA 意思決定理論と統合された「RCT-OODA 群制御 AI アーキテクチャ」の根幹として設計されたものである。

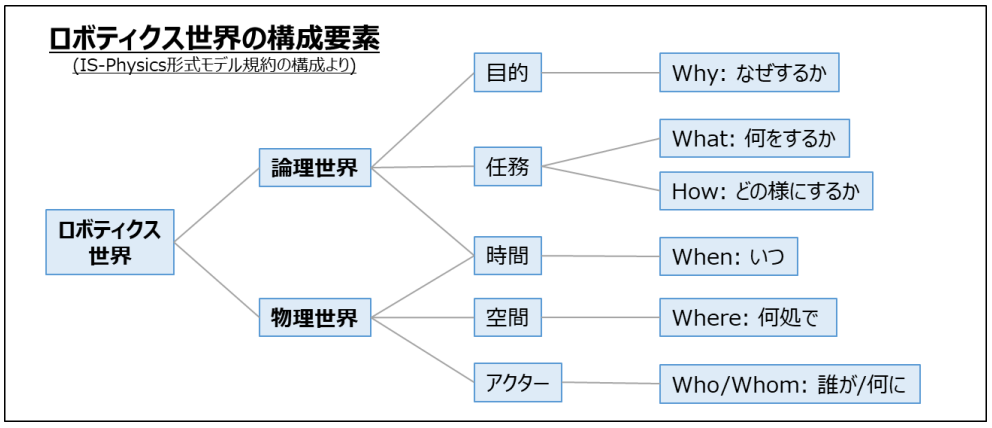

図　３．１．２－１４　ロボティクス世界の構成要素

定義：IS-Physics 形式モデル規約は、AI による状況認識・意思決定・群制御において、物理的・空間的情報を適切に抽象化・構造化・数値化するための共通記述仕様である。本規約は、CAE（Computer-Aided Engineering）技術の設計思想に基づき、情報の粒度や構造表現様式を調整可能とすることで、高信頼かつ資源効率の高い RCT 世界モデル（AI 認知思考・群制御データモデル

基盤)を提供する。

本規約の名称に含まれる「IS」は「InterSwarm」の略称であり、複数のエージェント群が連携・協調しながら複雑環境下で知的行動を発揮するシナリオを想定した設計思想に由来する。従来の論理中心の記述方式とは異なり、本規約は物理的構造と意味的構造を両立させる計算力学的視点に立脚し、知能の身体性を内包する AI 記述様式の標準化を目指している。

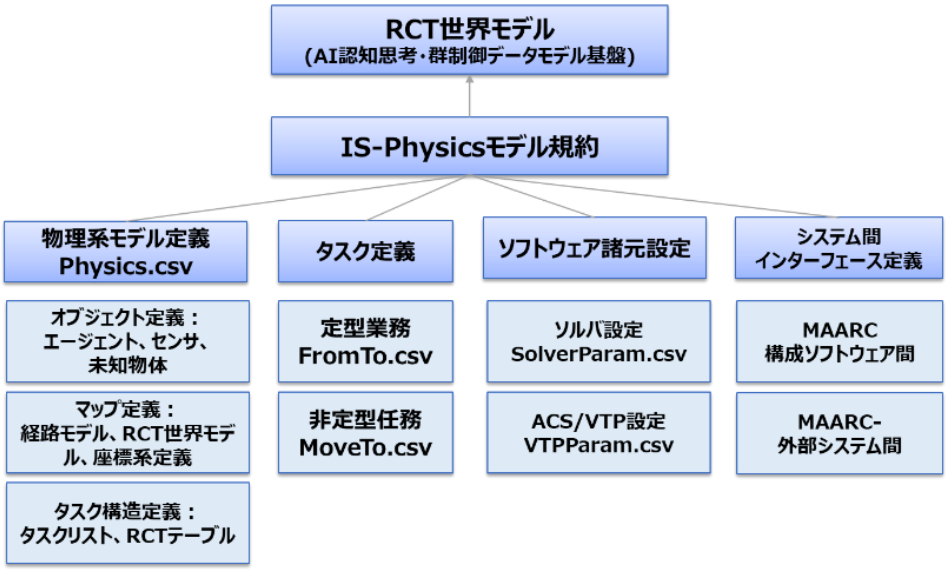

図　３．１．２－１５　IS-Physics 形式モデル規約の構成

特徴および機能：IS-Physics 形式モデル規約は、AI の知的処理と物理的行動を統合するための共通記述仕様として、以下の機能を備える。

まず、本規約は、RCT 世界モデルにおいて、**空間・構造・意味の統合記述**を可能にする。空間的配置、構造的関係、行動に関わる意味的情報を統一的に記述することで、知覚・構造・意味・行動の階層モデルを一貫して表現できる。この構造により、AI の状況認識と判断における透明性・整合性が確保される。

次に、**意思決定と群制御の共通仕様**として、物理現象と論理的推論の橋渡しを行い、汎用的かつ再利用可能な意思決定支援システムの設計を支援する。これにより、多様な応用分野への展開が容易になる。

また、本規約は **AI の身体性の設計支援**を可能とする。物理的制約や環境との相互作用をモデルに組み込むことで、AI が実世界において適切に行動するための基盤を提供する。

さらに、**制御性と最適化適合性**に優れており、モデル構成は入力ファイルとして定義可能である。これらのデータは AI による設計変数として扱うことができ、最適化や設計シミュレーションを実現する(図　３．１．２－１６参照)。

今後の展開：本研究では、IS-Physics 形式モデル規約を基に、汎用性の高い静的記述モデルを構築しつつある。今後はこれを拡張し、動的環境変化に適応可能なリアルタイムモデル生成機構の開発へと展開し、AI による知的処理と身体的行動の高度な統合を実現していく予定である。

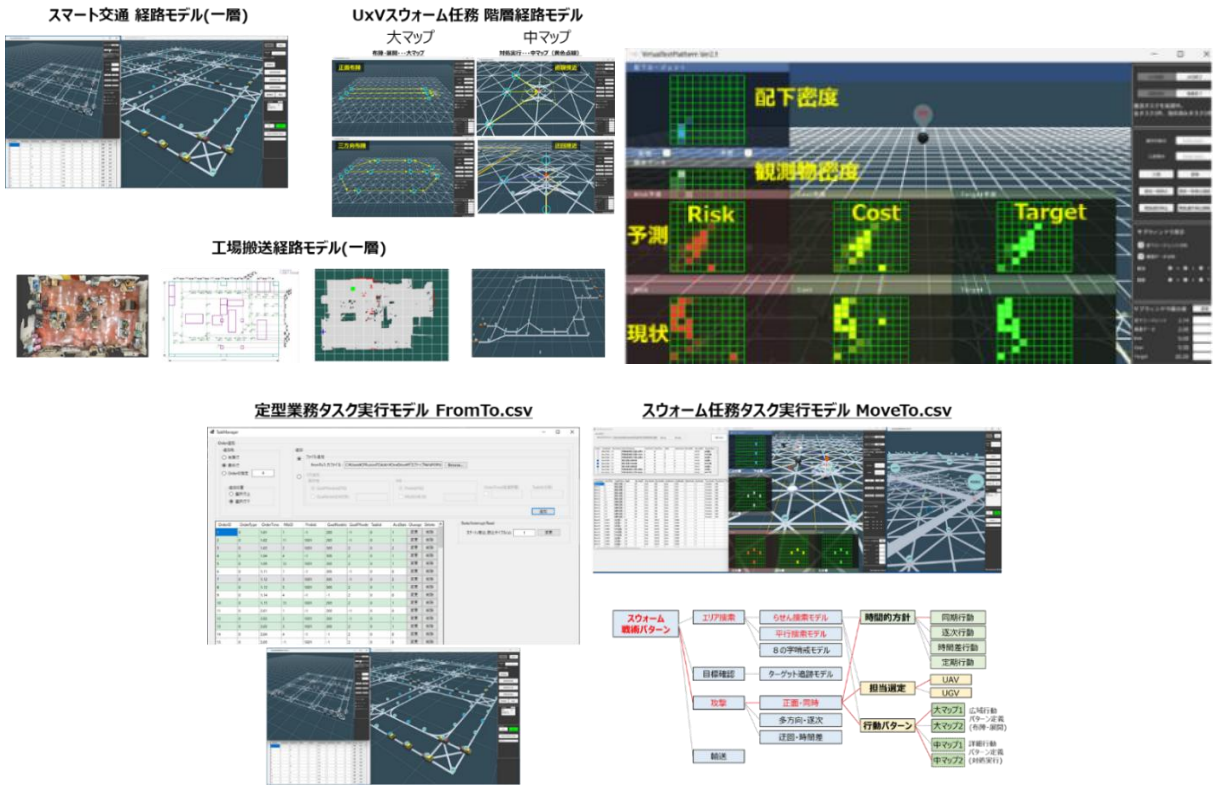

図　３．１．２－１６　IS-Physics 形式モデル規約による各種モデル設定

３．１．２．８ MAARC(汎用マルチエージェント基盤)の構築

（１） 定義と目的

MAARC（Multi-Agent Architecture for Autonomous Reasoning and Control）は、**無人機群の任務遂行における意思決定と群制御の OODA ループを統合的に自律化**するために構築された、汎用かつ拡張性の高いマルチエージェント AI 基盤である(図 ３．１．２-１７参照)。本基盤は、研究開発から社会実装までを見据え、実機群制御を対象とした評価と運用環境を提供する。

図 ３．１．２-１７ MAARC による OODA ループ自律化コンセプト

（２） システム構成

MAARC は以下のサブシステム群から構成される。

- **IS-Physics 形式データモデル**：任務世界、無人機諸元、タスク等の諸元を統合記述する標準仕様。AI モデルと物理構造の整合を保証する。
- **OODA 群制御 AI**：エージェント群の観測データから状況認識・意思決定を行い、配車・経路・空域誘導など広域統合制御を実行。
- **ACS（Agent Control System）**：OODA 群制御 AI からの制御コマンドを実機に送信し、逆に観測情報を取得して AI にフィードバックする中核制御システム。
- **VTP（Virtual Test Platform）**：仮想エージェント応答再現および実機のデジタルツイン環境を兼ね備えた評価環境。AI 誤判断の検出・警告機能も有する。
- **AI SLPF（AI Self Learning Platform）**：AI の学習と性能評価のための実験環境。
- **HSI UI**：ACS-VTP に組み込まれた GUI は、認知負荷・操作負荷を低減し、HSI（Human Swarm Interaction）を支援する。
- **スウォーム IF**：外部システムと接続する通信インターフェース。座標系変換、データ変換等を行い、相互運用性を高める。
- **外部システム**：外部システムは、実機システムだけでなく、高忠実シミュレータを含む。本研究では、**遠隔制御システム HTAT と搬送 UGV により**遠隔監視・異常系対処が可能な CPS 環境を構築した。

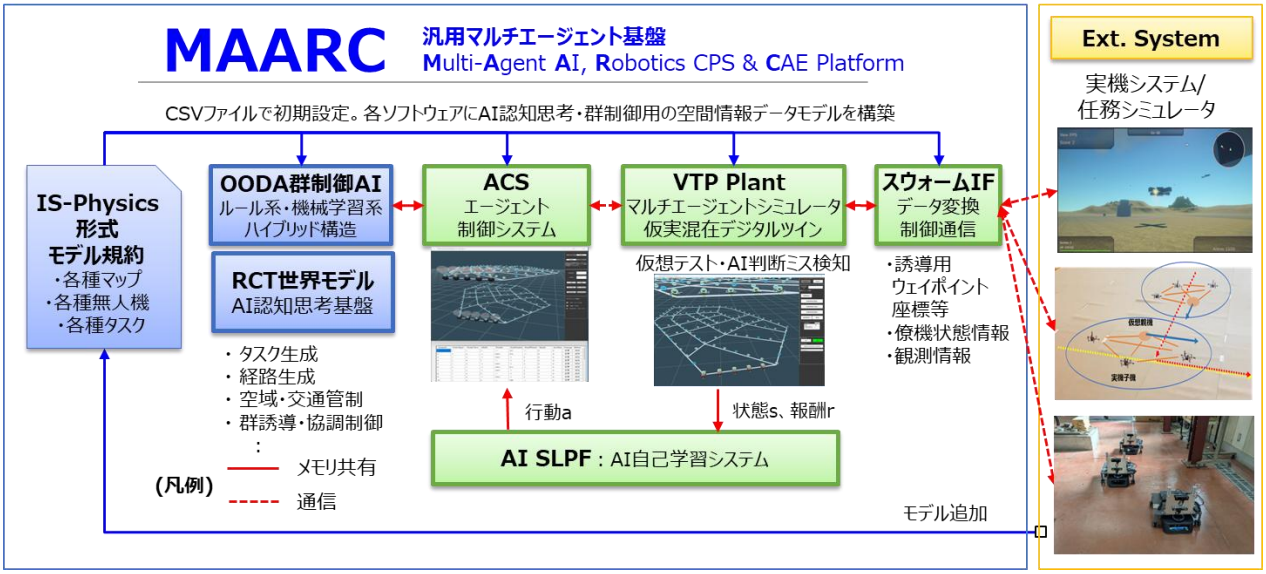

図　３．１．２－１８　MAARC システム構成

（３）　利用場面

MAARC は、RCT-OODA 群制御 AI アーキテクチャの設計思想を具現化した実証環境として、AI 研究・モデル開発・任務設計・評価・訓練・実運用の各段階において活用可能な統合プラットフォームである(図　３．１．２－１９、図　３．１．２－２０参照)。各フェーズは、利用者の役割に応じて以下のように展開される。

AI 研究フェーズ（主担当：研究者）：研究者は、MAARC に独自 AI を組み込み、その性能やロジックを評価できる。モデリングは、IS-Physics 形式モデル規約により入力ファイルで設定可能。研究者は環境構築の手間を省いてアルゴリズム開発に専念することが可能である。

モデル開発フェーズ（主担当：開発者）：開発者は、任務技術者の要求に応じて、無人機や運用環境の構成要素をモデル化し、既存モデルライブラリを拡張する。

任務設計・モデリングフェーズ（主担当：任務技術者）：任務技術者は、運用者との対話に基づいて任務要求を定式化し、群構成、AI 諸元、タスク構造、地図などの設計変数を最適化する。

仮想環境評価フェーズ（主担当：任務技術者）：マルチエージェントシミュレーションを行い、任務設計の有効性を定量評価する。分析結果をもとに設計の改良を繰り返す。

実環境評価フェーズ（主担当：任務技術者＋運用者）：シミュレーション評価で絞り込まれた設計内容をもとに、必要最小限の実機試験を実施する。仮想・実機のギャップや実運用時の安全性を確認する。

仮想訓練フェーズ（主担当：運用者）：最適化された運用設計に基づき、運用者（任務責任者・操縦者等）は仮想環境で訓練を行い、操作手順や任務遂行に熟練する。

実機訓練フェーズ：仮想訓練を終えた後、実機環境にて操作・運用スキルの完成度を高める。

実運用フェーズ（主担当：運用者）：訓練を経た運用者が実環境で任務遂行を行う。運用中に取得された行動データや群制御ログは、AI 学習や設計フィードバックのため蓄積され、再学習に利用される。これにより、MAARC は自己進化的なシステム設計サイクルを支える。

このように MAARC は、研究・設計・評価・訓練・運用の各段階を一貫して支援し、知能設計から現場適用までを橋渡しするマルチエージェント AI システム開発の中核基盤として機能する。特に、RCT-OODA アーキテクチャに基づく構造的な意思決定・群制御設計を物理的運用に適用できる点が、他に類を見ない特徴である。

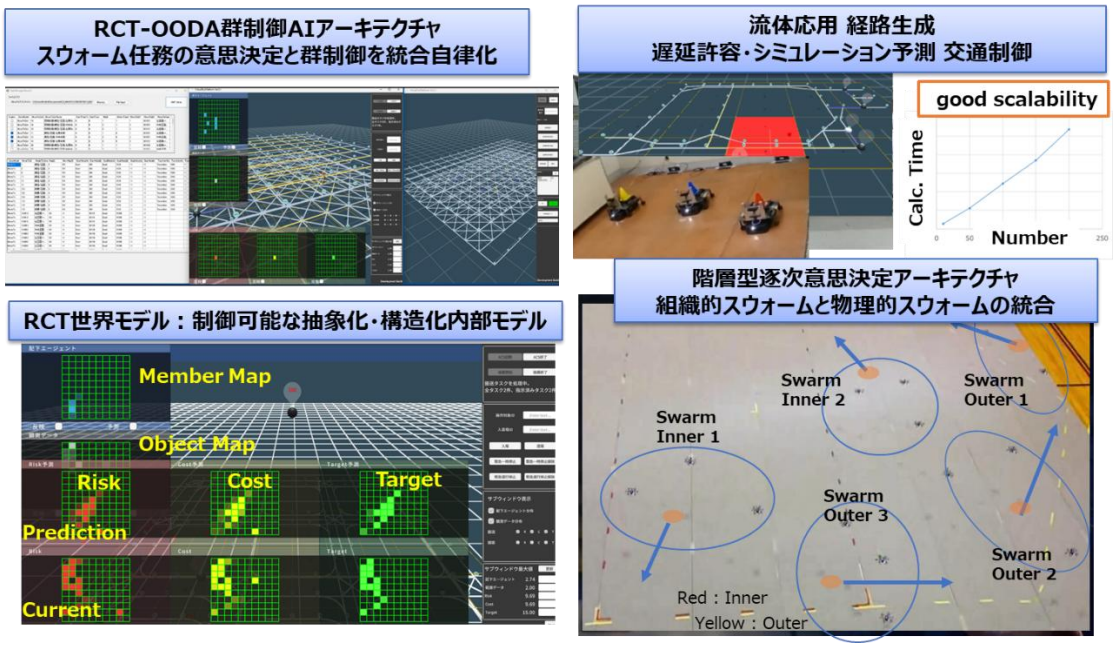

図　３．１．２－１９　MAARC 利用例

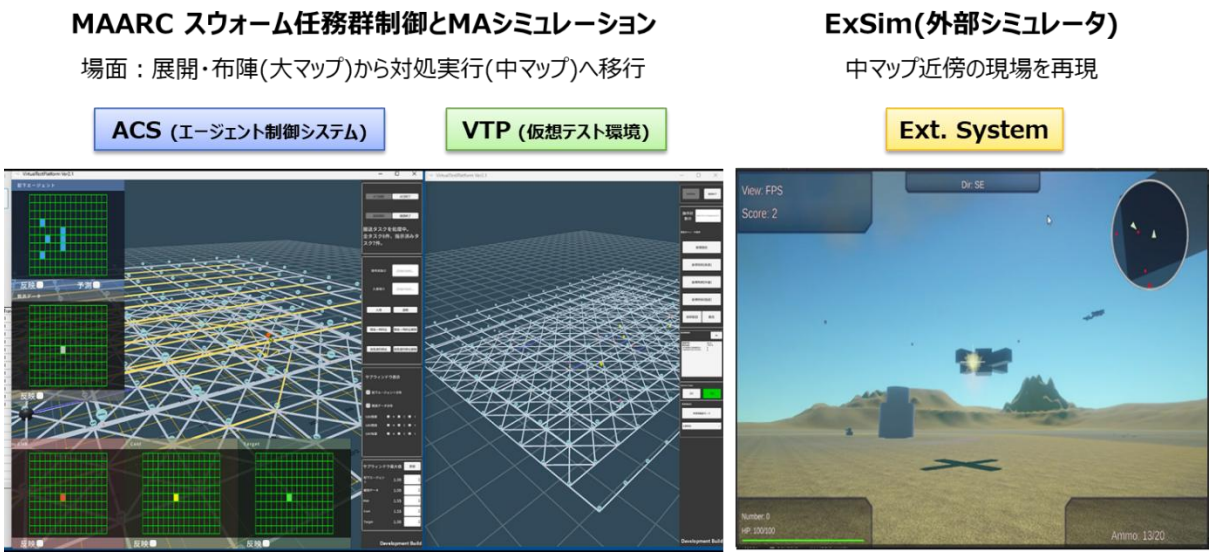

図　３．１．２－２０　MAARC による捜索・救難・警備スウォーム任務実行例

３．１．２．９ 新AIアーキテクチャの機能実証・性能評価

（１） 意思決定と群制御の OODA ループ自律化の機能実証

結論：本実証により、RCT-OODA群制御AIアーキテクチャによる「OODAループ自律化機能」が、実環境下の複数シナリオにおいて安定して動作し、AIによる状況認識・判断・行動の統合制御が実機において成立することを確認した(表 ３．１．２-６参照)。
これにより、実機適用に向けた信頼性と実用性の技術的基盤が確立された。

試験概要：
試験場所：日本大学生産工学部 振動実験室（図 ３．１．２-２１参照）
評価対象：RCT-OODA群制御AIアーキテクチャ(MAARC + 無人機システム)
使用機材：無人搬送機（Kachaka）、遠隔監視システム（HATS）

実証目的：AIによるOODAループ(観測・状況認識・意思決定・行動実行)の全体を、MAARCのCPS環境下で自律化し、実際の物理空間で動作するかを検証する。

手法：遠隔監視制御システム（HATS）および無人搬送機（kachaka）を用いた実機システムに、MAARCを接続し、Sim2Realギャップに対する安全性を考慮したCPSアーキテクチャを構築した。VTP内に構成されるリアルタイムデジタルツイン経由で、AIが実機の応答を意思決定に反映させる制御フローを実装した。さらに、MAARCと実機システム間を接続するSwarm IF（スウォーム・インターフェース）を詳細設計・実装し、通信プロトコルや連携仕様を整備した。

総括：本実証により、RCT-OODA群制御AIアーキテクチャが、複数移動体の交通管制・動的リスク回避を実現可能であり、意思決定と群制御の自律化に対応できることが確認された。これにより、マルチエージェントAIの基盤技術としてのMAARCアーキテクチャの信頼性・応用性が実証された。今後は、複雑環境・多数機・異種エージェント混在環境への拡張へと発展可能である。

表 ３．１．２-６ 実機テスト想定シナリオと結果概要

#	想定シナリオ名称	結果概要	備考
0	通常時（比較用）	動的リスクが存在しない場合には最短経路を生成した。	合格
1	定点カメラ物体検知・リスク迂回	定点カメラが物体検知しリスク判定→リスク回避する経路を生成・再生成した。	合格
2	移動体カメラ物体検知・リスク迂回	移動体が物体検知しリスク判定し、他の移動体がリスク回避する経路を生成・再生成した(図 ３．１．２-２２参照)。	合格（図示）
3	渋滞迂回	移動体2台が渋滞し、他の3台の移動体が渋滞回避して迂回する経路を生成した。	合格
4	T字合流制御	T字路で左右から移動体2台・3台が合流地点に向かい、ACSの指示に従い待合氏、1台ずつ通過した。	合格
5	長距離テスト	システムの安定性、可用性の簡易評価。18分程度走行し、最終的に5台中4台を撤去したが、最後の1台は全てのゴールをこなした	合格

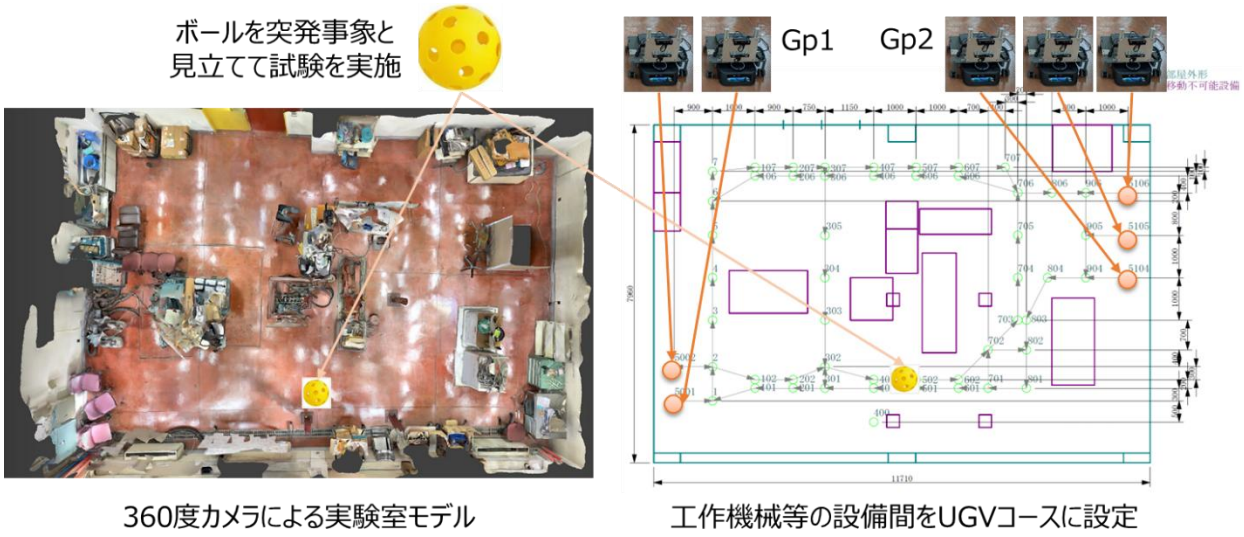

図　３．１．２－２１　実機テスト試験場概要（日本大学生産工学部振動実験室）

想定シナリオ＃２　移動体カメラ物体検知・リスク迂回　ケース図示

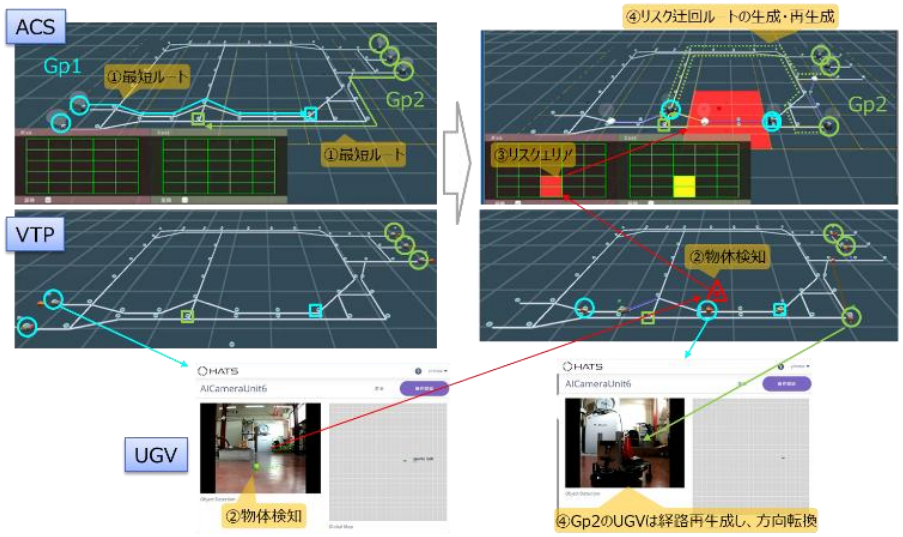

図　３．１．２－２２　想定シナリオ＃２　移動体カメラ物体検知・リスク迂回　ケース図示

（２） スマート交通スループット最適化：複合 AI 設計の評価

結論：OODA群制御AIにおけるロジック支援型AIは、信頼性・適応性・最適性を兼ね備えたアーキテクチャとして機能し、複合AI設計が動的状況に対応した全体最適化を実現できることを仮想テスト試験により評価実証した。

目的：OODA群制御AIの中核要素である複合AI設計について、以下の２点を評価目的とした。

1. ロジック支援型AIの複合AI設計が、信頼性の源泉として実際に機能するか。(図 ３．１．２-２３、表 ３．１．２-７、表 ３．１．２-８参照)
2. 動的状況変化を踏まえた全体最適化が、有効に働くかどうか

手法：スマート交通システム(図 ３．１．２-２５参照)を評価シナリオとし、所定の搬送オーダーに対するスループット最適化(総搬送時間)を評価指標とした。比較対象として、以下の3構成による経路生成戦略を設定し、同条件下で性能比較を行った。

1. 距離最小化・ルールベースAI単体：静的な最短距離経路を生成(評価基準)
2. Path上混雑度考慮・時間最小化・ルールベースAI単体：
3. Path上混雑度考慮・時間最小化・ロジック支援型AI：
4. Area内混雑度考慮・時間最小化・ルールベースAI単体：
5. Area内混雑度考慮・時間最小化・ロジック支援型AI：

ここで、ルールベースAIの時間最小化経路生成は、経路生成時、移動体密度を移動コストに付加し、最小時間の経路を探索する方式をとっている。

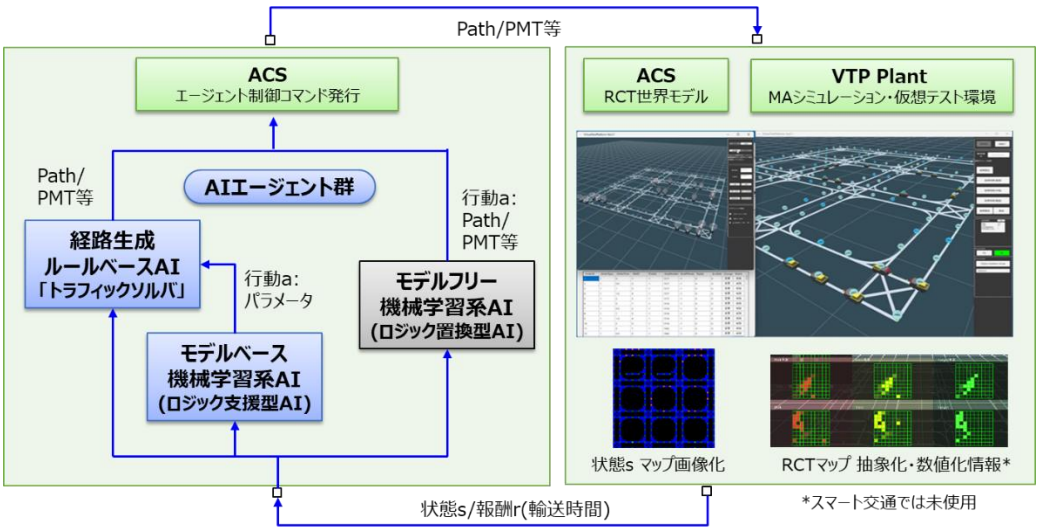

図 ３．１．２-２３ AI 学習環境

表 ３．１．２-７ AI モデル構成

AI種類	モジュール・モデル	内容
ルールベースAI	トラフィックソルバ	経路生成の二方式を最適化対象とする。 ・方式１：Pathベース経路生成 ・方式２：Areaベース経路生成
機械学習系AI	DQN強化学習	方式１、２の渋滞考慮係数を最適化する。

表 ３．１．２-８ 機械学習系 AI の入出力条件

項目	内容	備考
状態s	経路マップ、各無人機の位置情報	画像データ
報酬r	ステップ報酬：ステップ内オーダーの搬送完了時間 エピソード報酬：総搬送時間	１エピソードNステップ 報酬付与はステップ毎
行動a	トラフィックソルバの渋滞考慮係数 (Path基準、Area基準)	

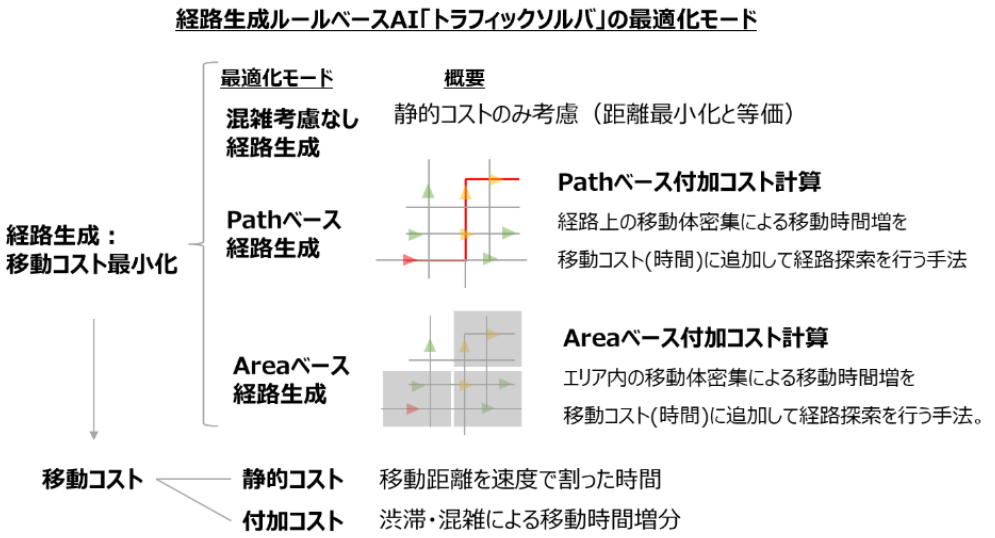

図　３．１．２－２４　経路生成ルールベース AI「トラフィックソルバ」の最適化モード

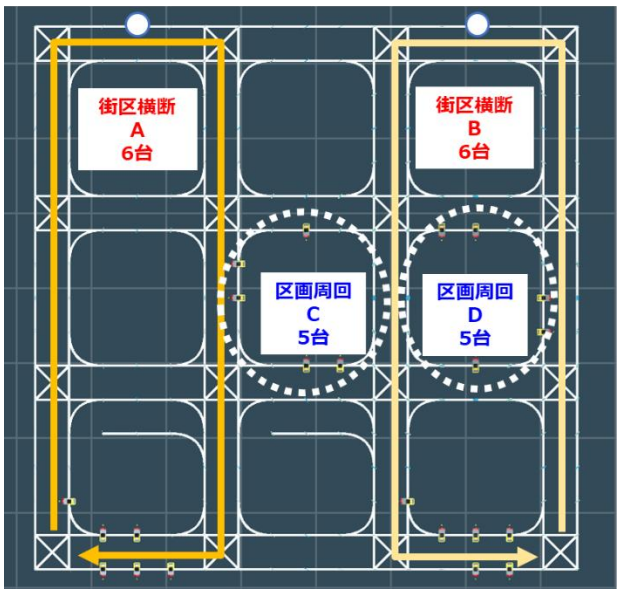

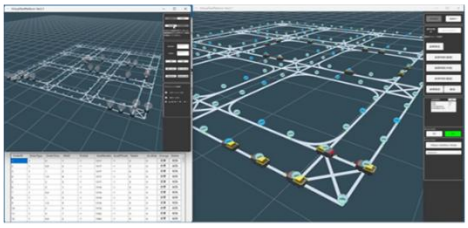

任務種類	チーム	台数	タスク数
街区横断	A	6台	54
	B	6台	54
区画周回	C	5台	140
	D	5台	140

図　３．１．２－２５　スマート交通経路モデル

結果：検証の結果、複合AI構成は以下の観点で優れた性能を示した（表　３．１．２－９参照）。

- 状況適応性の向上：
  ・動的な交通状況や混雑状況に柔軟に対応し、オーダー遂行にかかる時間を低減
  Path基準：ルート上の混雑度を考慮した経路生成により、7.1%の時間短縮を達成
  Area基準：エリア内の混雑度を考慮した経路生成により、14.1%の時間短縮を達成
- 運用安定性の確保：
  ・ルールベースの予測可能性を活かしつつ、機械学習AIにより動的対応能力を強化
- 全体最適化の有効性：
  ・複数オーダー・複数車両の同時運用においても、スループット最適化に効果を発揮

以上により、OODA群制御AIにおける複合AI設計は、実環境下でも実効性を発揮するアーキテクチャであり、信頼性・適応性・運用最適性の三要素を高水準で両立可能であることが確認された。

表　３．１．２−９　機械学習系 AI の入出力情報と最適化結果

経路生成方式	AI構成	ステップ数・ タスクリスト分割数	平均総搬送時間 単位:秒（比率）	備考
混雑考慮なし 移動時間最小化	**ルールベースAI**	**１ステップ・分割なし**	**498.7 (100)**	**基準**
Pathベース経路生成 Path上混雑考慮 移動時間最小化	ルールベースAI	１ステップ・分割なし	478.6 (95.9)	
	ロジック支援型AI (ルールベース ＋DQN複合AI)	２ステップ・２分割	485.3 (97.3)	
		３ステップ・３分割	463.5 (92.9)	効果あり
Areaベース経路生成 Area内混雑考慮 移動時間最小化	ルールベースAI	１ステップ・分割なし	428.4 (90.2)	
	ロジック支援型AI (ルールベース ＋DQN複合AI)	２ステップ・２分割	426.7 (89.9)	効果あり
		３ステップ・３分割	**407.8 (85.9)**	**効果あり**

３．１．２．１０ 結言：新規性・独創性・革新性のポイント

以上により、本研究は、マルチエージェント AI による次世代無人機運用の中核技術として、組織的な意思決定能力と群制御能力を統合的に具備した AI 基盤技術体系を初めて提示したものと位置づけられる。本技術体系は、**設計原理・アーキテクチャ・要素技術・システム統合**を学術横断的に構築しており、以下の点において新規性・独創性・革新性を備えると言える。

表　３．１．２−１０　新規性・独創性・革新性

【新規性】

- 実務経験に基づく専門家の**エキスパート思考様式**および**絵図的知能**に着想を得た、新たな AI 原理「絵図・知識・運動系 AI」を提唱。
- 認知・思考・行動を統合する「RCT-OODA 群制御 AI アーキテクチャ」を設計し、AI・ロボティクス・CAE を統合的に扱う新アーキテクチャの構築と分散化を計画。

【独創性】

- RCT 世界モデルにより**実世界を抽象化・構造化・数値化**し、状況認識・意思決定・行動を統合。
- OODA 理論、計算力学・CAE、航空機設計法、登山計画・読図技術など、**実務に根差した異分野技術**を AI 設計へ融合。
- 開発アーキテクチャを「**汎用マルチエージェント基盤 MAARC**」（図(2)-3 参照）として実装し、**実機とシミュレーションで概念検証**。さらに、**物理的分散化と半自律化**を計画。

【革新性】

- 従来の AI 設計とは異なる、**直感的・分散的・実用的な意思決定・群制御の枠組み**を確立。
- 本アーキテクチャは、「**人スウォーム協調型 HSI**」の設計・実装にも展開可能であり、設計から社会実装まで**一貫した実証体系**を構築。
- **学術的基盤と産業的応用を両立**する革新的**マルチエージェント AI 基盤**を提供。

３．１．３ 本研究の位置付けと成果の自己評価

３．１．３．１ 本研究内容の学問領域における位置付け

JST CRDS の資料を引用し、本研究内容の位置付けを示す。

（１） システム・情報科学技術分野における本研究の位置付け（図 ３．１．３－１参照）

本研究は、MAARC の工学的区分「マルチエージェント AI、マルチエージェント Robotics CPS、マルチエージェント CAE」が、システム・情報科学技術の主要俯瞰区分である「人工知能・ビッグデータ」「ロボティクス」「数理科学」に該当し、横断的かつ統合的な研究領域に属する。

本研究がシステム・情報科学技術分野における知能設計・実装の中核的課題に対して、知能、制御、モデリングと最適化の三側面からアプローチするものであることを示している。

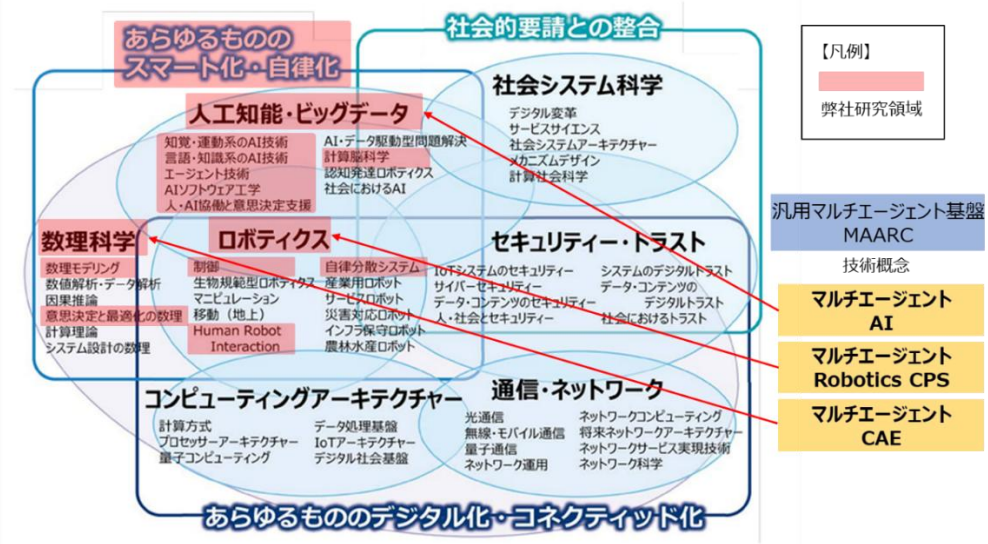

図 ３．１．３－１ 弊社要素技術の位置付け：システム・情報科学技術分野の俯瞰図との関係

出典）JST，CRDS-FY2024-FR-03，研究開発の俯瞰報告書 システム・情報科学技術分野（2024 年）図 1-1-2

（２） システム・情報科学技術分野の研究開発領域における本研究の位置付け

本研究とシステム・情報科学技術分野における研究開発領域の該当領域の関連性を表 ３．１．３－１に示す。この表の備考欄に、直接的な項目は★印を、間接的な項目は〇印を付している。※印のシステムのデジタルトラストは、CPS におけるシステム間のデジタルトラストである。AI 信頼性は、俯瞰区分 2.1.4 項の課題である。

表 ３．１．３－２は、日本の研究開発政策における重点課題と本研究が関連する研究開発領域の関連性を示すものである。本研究は、我が国の科学技術・イノベーション政策が掲げる重点分野「人工知能・ビッグデータ」の中でも、「スマート化・自律化の根本である知能の原理探求」に該当する領域に属する。

本研究は、専門的な思考様式と絵図的知能に基づく新アーキテクチャ「RCT-OODA 群制御 AI アーキテクチャ」に準拠した、意思決定と群制御を統合・自律化するマルチエージェント AI アーキテクチャの開発を通じて、分散知能システムの原理解明とその工学的実装に挑戦している。これは、AI 技術の応用的深化にとどまらず、意思決定・推論・状況理解などの基盤的知能機能をいかに構築するかという本質的な課題である。このように、本研究は「スマート化・自律化」の基盤技術に直結する課題に取り組むものであり、日本の AI 研究が直面する知能の構造化・説明可能化・信頼性確保といった中長期的課題に対し、独自の理論と実装技術によって応答するものである。

表　３．１．３－１　弊社技術の位置付け：システム・情報科学技術分野の俯瞰区分との関係

出典）JST，CRDS-FY2024-FR-03，研究開発の俯瞰報告書 システム・情報科学技術分野（2024 年）表 1-1-1 に備考を筆者追加 弊社研究に関連するものを備考欄に★印をつける。〇は間接的に寄与するものである

俯瞰区分	研究開発領域	備考
2.1 人工知能・ビッグデータ	2.1.1 知覚・運動系のAI技術	★
	2.1.2 言語・知識系のAI技術	★
	2.1.3 エージェント技術	★
	2.1.4 AIソフトウェア工学	★
	2.1.5 人・AI協働と意思決定支援	★
	2.1.6 AI・データ駆動型問題解決	★
	2.1.7 計算脳科学	★
	2.1.8 認知発達ロボティクス	★
	2.1.9 社会におけるAI	〇
2.2 ロボティクス	2.2.1 制御	★
	2.2.2 生物規範型ロボティクス	
	2.2.3 マニピュレーション	
	2.2.4 移動（地上）	
	2.2.5 Human Robot Interaction	★
	2.2.6 自律分散システム	★
	2.2.7 産業用ロボット	
	2.2.8 サービスロボット	
	2.2.9 災害対応ロボット	
	2.2.10 インフラ保守ロボット	
	2.2.11 農林水産ロボット	
2.3 社会システム科学	2.3.1 デジタル変革	
	2.3.2 サービスサイエンス	
	2.3.3 社会システムアーキテクチャー	〇
	2.3.4 メカニズムデザイン	〇
	2.3.5 計算社会科学	

俯瞰区分	研究開発領域	備考
2.4 セキュリティー・トラスト	2.4.1 IoTシステムのセキュリティー	
	2.4.2 サイバーセキュリティー	
	2.4.3 データ・コンテンツのセキュリティー	
	2.4.4 人・社会とセキュリティー	
	2.4.5 システムのデジタルトラスト	※
	2.4.6 データ・コンテンツのデジタルトラスト	
	2.4.7 社会におけるトラスト	
2.5 コンピューティングアーキテクチャー	2.5.1 計算方式	
	2.5.2 プロセッサーアーキテクチャー	
	2.5.3 量子コンピューティング	
	2.5.4 データ処理基盤	〇
	2.5.5 IoTアーキテクチャー	
	2.5.6 デジタル社会基盤	
2.6 通信・ネットワーク	2.6.1 光通信	
	2.6.2 無線・モバイル通信	
	2.6.3 量子通信	
	2.6.4 ネットワーク運用	
	2.6.5 ネットワークコンピューティング	
	2.6.6 将来ネットワークアーキテクチャー	
	2.6.7 ネットワークサービス実現技術	
	2.6.8 ネットワーク科学	
2.7 数理科学	2.7.1 数理モデリング	★
	2.7.2 数値解析・データ解析	
	2.7.3 因果推論	
	2.7.4 意思決定と最適化の数理	★
	2.7.5 計算理論	
	2.7.6 システム設計の数理	

表　３．１．３－２　弊社技術の位置付け：国として重点的に取り組むべき研究開発課題との関係

出典）JST，CRDS-FY2024-FR-03，研究開発の俯瞰報告書 システム・情報科学技術分野（2024 年）表 1-3-1 に加筆

	国として重点的に取り組むべき研究開発課題	4つのシナリオ (1) 強い技術を核とした骨太化	(2) 強い産業の発展・革新の推進	(3) 社会課題の先行解決	(4) 経済安全保障上の重要基盤技術の確保
デジタル安全保障に対する総合知による取り組み	デジタル社会におけるトラスト形成	●		●	●
	コグニティブセキュリティー			●	●
	データ共有		●		●
スマート化・自律化の根本である知能の原理探求	知能モデルの解明・探究／身体性に宿る知能	●	●		
	人間中心インタラクション	●		●	
	バイオハイブリッドロボット	●	●		
	最適化	●			●
サステナブル社会のためのICT基盤	社会課題解決に向けたメタバースデザイン			●	●
	ネットワークのスマート化	●	●		●
	社会デジタルツイン				●
	社会システムを支えるAIアーキテクチャー	●			●

研究開発領域
「2.1.1 知覚・運動系のAI技術」
「2.1.2 言語・知識系のAI技術」
「2.1.7 計算脳科学」
「2.1.8 認知発達ロボティクス」
「2.2.6 自律分散システム」

研究開発領域：
「2.1.3 エージェント技術」
「2.2.5 Human Robot Interaction」

研究開発領域：
「2.7.1 数理モデリング」
「2.7.3 因果推論」
「2.7.4 意思決定と最適化の数理」
「2.7.5 計算理論」

研究開発領域：
「2.1.3 エージェント技術」
「2.1.5 人・AI協働と意思決定支援」
「2.3.3 社会システムアーキテクチャー」
「2.3.4 メカニズムデザイン」
「2.5.4 データ処理基盤」

（３） 俯瞰区分「人工知能・ビッグデータ」における本研究の位置付け

本研究は、図 ３．１．３－２に示す「人工知能・ビッグデータ」の研究に関連が深い。これを、OODA 意思決定理論の枠組みに沿って整理したものを図 ３．１．３－３に示す。

現状の AI は、OODA ループのうち観測（Observe）および実行（Act）の領域において進展しており、画像認識・音声処理・ロボット制御といった実用技術が確立されている。一方で、知能と身体性を繋ぐ部分、即ち、状況の解釈（Orient）や意思決定（Decide）の部分は、AI 技術間の連携や統合が十分に進んでいない。本研究は、これらの課題となっている部分(赤点線で示す)への取組みであり、OODA ループ全体を貫くマルチエージェント AI アーキテクチャの確立を目的としている。

また、マルチエージェント AI の研究は、シミュレーションを活用した学習と検証が不可欠であるが、その共通基盤が不十分であり、研究準備のモデル化・環境構築作業が大きな負担となっている。AI 研究に先立つ「モデル準備段階」の困難さが、本質的な研究と社会実装の阻害要因となっている。本研究では、このような背景を踏まえ、汎用性の高い計算力学や CAE 技術を応用したモデル規約とそれに基づく RCT 世界モデルにより、あらゆるユースケースに対応できる汎用性の高いマルチエージェント AI アーキテクチャを構築する。これにより、OODA ループ全体をまたぐ知能の身体性を実現し、シミュレーションと実機の両方で検証可能な研究基盤の確立を目指す。

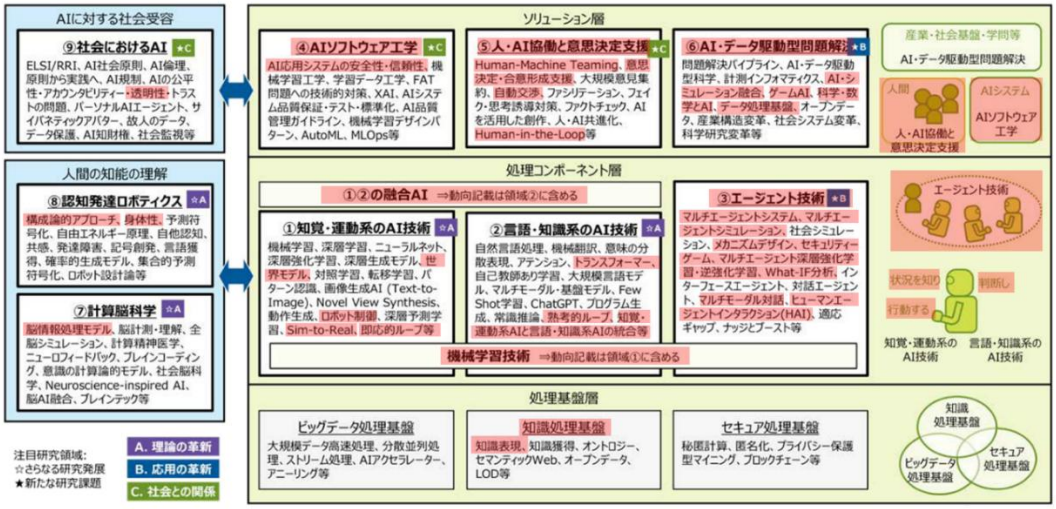

図 ３．１．３－２ 弊社要素技術の位置付け：俯瞰区分「人工知能・ビッグデータ」との関係

出典）JST, CRDS-FY2024-FR-03, 研究開発の俯瞰報告書 システム・情報科学技術分野（2024 年）に、関連領域を赤網掛けで図示

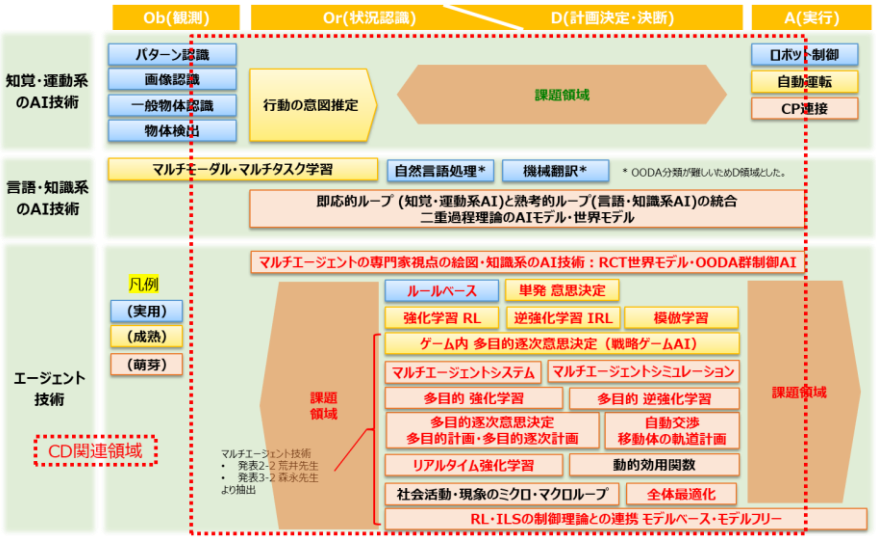

図 ３．１．３－３ 弊社要素技術の位置付け：「人工知能・ビッグデータ技術の俯瞰図」OODA 整理

出典）JST, CRDS-FY2024-FR-03, 研究開発の俯瞰報告書 システム・情報科学技術分野（2024 年）図 2-1-2 を OODA で整理。各要素で研究が進んでいる。エージェント技術に萌芽的な研究が多く、要素間をつなぐ部分に課題が多い。

（４）　弊社 RCT-OODA 群制御 AI モデルと二重過程理論 AI モデルの比較：

図　３．１．３－４に、弊社が開発する RCT-OODA 群制御 AI モデルと、次世代 AI 設計の一例とされる二重過程理論に基づく AI モデルとの比較を示す。左図に示す RCT-OODA 群制御 AI モデルは、以下の三つの構成要素を基盤とする AI アーキテクチャである：

- 専門家の認知思考様式（判断の勘所や情報粒度の一致）
- OODA 意思決定理論（Observe-Orient-Decide-Act）
- CAE（計算力学）における抽象化・構造化・可視化の手法

本モデルは、任務構造（Reference, Context, Task）と評価軸（Risk, Cost, Target）からなる多次元構造「RCT 世界モデル」に基づき、状況判断・意思決定・群制御を一体的に行う。これにより、分散エージェントが現場状況に応じて協調的に行動できる、高信頼・高柔軟な AI 制御が可能となる。

右図に示す二重過程理論 AI モデルは、人間の脳内情報処理や認知発達過程に着想を得た AI 設計の潮流を示しており、たとえば「知能の 2 階建てモデル」（松尾豊）に代表されるように、直感的・反射的な第 1 システムと、論理的・分析的な第 2 システムを階層的に統合するものである。

両モデルは、いずれも人間の認知機構に着目している点で共通するが、RCT-OODA 群制御 AI は意思決定と群制御を統合し、実行段階まで含めて工学的に形式化・分散実装できる点で応用可能性が高く、特に防災・警備・輸送といった実環境での運用に強みを有している。

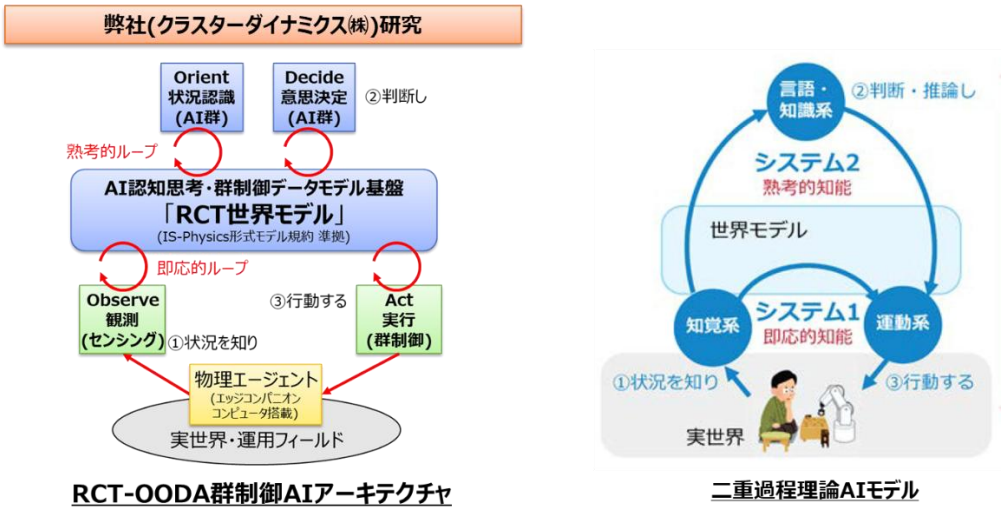

図　３．１．３－４　弊社 RCT-OODA 群制御 AI モデルと次世代 AI モデル「２重過程理論 AI モデル」の比較

概要：左図は専門家の認知思考様式・絵図型知識表現に、OODA 意思決定理論と CAE の抽象化・可視化手法を応用した AI モデル。RCT は任務構造(Reference, Context, Task) ×評価軸(Risk, Cost, Target)を意味する。右図は JST, CRDS-FY2023-SP-03, 次世代 AI モデルの研究開発, 図 B-1-2 二重過程理論と AI モデルである。人間の脳情報処理・認知発達過程に基づく AI モデル。

（５） 第４世代 AI と信頼される AI における課題と本研究の対応方針

現在、「人工知能・ビッグデータ」領域における技術潮流は、大きく分けて第 4 世代 AI（知識とデータの融合）と、信頼される AI（Trustworthy AI）という 2 つの方向性に展開している。これらに関する技術的課題と対処方針を、表 ３．１．３-３および表 ３．１．３-４に示す。

第 4 世代 AI は、機械学習に加えて知識構造や推論能力との統合が求められており、学習資源の過大要求や汎化能力の限界が深刻な課題として認識されている。また、信頼される AI に関しては、文脈理解・意図推論の困難さや、記号接地・フレーム問題、さらに AI の判断過程がブラックボックス化されることによる品質保証の困難性が、社会実装の障壁となっている。

本研究では、これらの課題に対し以下のようなアプローチにより対応を試みる：

- 学習資源の過大要求・汎化能力の限界に対しては、CAE 的抽象化・構造化手法を応用し、知識主導型の軽量 AI 設計（ルール・学習ハイブリッド）により克服する。
- 文脈理解・意図推論の限界に対しては、RCT 世界モデルにより、タスク構造と状況文脈を結合した認知的判断支援を可能とする。
- 記号接地・フレーム問題には、空間情報と物理情報を統合するモデリング規約に基づいた絵図情報の設計により、実世界における意味づけと推論の整合性を担保する。
- ブラックボックス性・品質保証の困難性については、AI の判断根拠を可視化する絵図情報と世界モデルを導入し、人間による理解・検証・介入が可能な形式での知識提示を実現する。

これらの対応を通じて、本研究は第 4 世代 AI と信頼される AI の両立を目指す、実環境指向のマルチエージェント AI 設計の基盤技術を確立するものである。

表 ３．１．３-３ 第４世代 AI の問題と対応方針（★印の項目を弊社課題として認識）

問題	対応方針
1. **★学習資源の過大要求**：大量の学習データと計算資源を必要とし、構築・運用コストが高い。 2. **★汎化能力の限界**：学習データ範囲外への適応や、未知環境への柔軟な対応が困難。 3. **★文脈理解と意図推論の限界**：深層学習はパターン認識には優れるが、文脈理解や意図推論など高次知能の処理ができない。 4. **★記号接地・フレーム問題**：言語・記号と知覚・行動との接続、予測困難な変化への柔軟対応が構造的に困難。	1. **★二重過程モデルの導入**：System1（即応的・直感的）と System2（熟慮的・論理的）を併せ持つ構成による認知機能の模倣。 2. **★予測誤差最小化原理の活用**：脳科学にもとづく認知モデルを導入し、環境との相互作用において期待と現実のズレを最小化。 3. **★自己組織化・発達知能の重視**：固定的な設計でなく、発達や環境変化に応じて柔軟に構造を変える創発的 AI の追求。 4. **★身体性と環境適応性の強化**：センサ・運動系との統合による実世界対応力の向上。

出典）JST, CRDS-FY2024-FR-03, 研究開発の俯瞰報告書 システム・情報科学技術分野（2024 年）

表 ３．１．３-４ 信頼される AI の問題と対応方針（★印の項目を弊社課題として認識）

問題	対応方針
1. **★ブラックボックス性：**深層学習を中心とした AI の判断根拠が不透明であり、説明責任が果たせない。 2. **★品質保証の困難さ：**機械学習の帰納型手法は 100%保証が困難であり、安全性や信頼性を確保する仕組みが未整備。 3. **社会的信頼の獲得不足：**技術的信頼性のみでは不十分で、ユーザーや社会が「信じられる」AI であるための受容性確保が課題。 4. **ガイドラインの定着不足：**QA4AI や AIQM などの品質管理ガイドラインは存在するが、現場での運用・社会受容の面で整備が不十分。	1. **★帰納型と演繹型の融合：**機械学習（帰納型）とルールベース（演繹型）のハイブリッド設計により、安全性と柔軟性の両立を図る。 2. **★Safe Learning 設計の導入：**演繹的に安全性を保証した「セーフティエンベロープ」の範囲内で、帰納型 AI を活用する方法を採用する。 3. **★説明可能性の確保（XAI）：**ユーザーが AI の動作や判断過程を理解できるようにし、安心感・納得感を支援。 4. **第三者認証・制度的枠組みとの連携：**AI 品質を評価・保証するための標準化や第三者機関による評価体制の整備。

出典）JST, CRDS-FY2024-FR-03, 研究開発の俯瞰報告書 システム・情報科学技術分野（2024 年）

３．１．３．２ 本研究内容の新規性、独創性、及び革新性

（１） 新規性

- **新原理「絵図・知識・運動系 AI」の提唱**
  専門家の認知様式と絵図的知能に基づき、認知（絵図）・知識（意味構造）・行動（運動）を統合する新たな AI 原理を提唱。状況理解から行動制御までを一貫した構造で設計可能とする。
- **「RCT-OODA 群制御 AI アーキテクチャ」の構築**
  OODA ループと構造化世界モデルを統合した新アーキテクチャを設計。個別判断と群としての適応行動を両立する分散型意思決定基盤として機能する。
- **「RCT 世界モデル」による状況理解支援**
  Reference, Context, Task × Risk, Cost, Target による 6 要素モデルにより、状況の構造化・数値化・可視化を実現し、AI の認知判断を支援する。
- **完全分散・半自律型 AI の実装**
  各無人機・ロボットに意思決定機能を分散実装し、通信断・環境変化下でも自律的に判断・協調可能なアーキテクチャを実現。
- **IS-Physics 形式モデル規約の導入**
  知覚・構造・意味・行動の抽象階層を形式化し、AI の構造記述・再利用・拡張を可能とする記述規約を導入。汎用性・異分野展開性を両立。
- **「情報粒度一致仮説」に基づく認知構造設計**
  状況認識と意思決定における情報の抽象度・粒度を一致させ、情報整合性と推論一貫性を保証する AI 認知設計原理を新たに提示。

（２） 独創性

- **異分野構造知の統合による AI 設計**
  CAE、航空機設計、登山計画などの構造的判断支援知を AI 設計に応用し、世界モデル・判断根拠・UI 設計に展開。実務知と AI 設計を接続する独創的アプローチ。
- **多層融合型意思決定構造の設計**
  OODA 理論、RCT 世界モデル、ルール・学習統合 AI を統合し、柔軟かつ構造的一貫性のある意思決定プロセスを実現。
- **人機協調に向けた判断根拠の可視化**
  AI の判断根拠を絵図・自然言語で表示し、人が直感的に理解・介入可能なユーザインタフェースを構築。認知工学と AI 設計を融合した構想。
- **論理-物理統合による知能構造の形成**
  抽象判断と物理行動を IS-Physics 形式で連結し、知識・運動一体型の AI を構築。経路選定や交通管制など、知識駆動行動の一貫制御を実現。

（３） 革新性

- **災害・警備環境対応の堅牢な群制御 AI**
  OODA 群制御 AI を用い、通信断・動的環境下でも分散自律的に判断・行動可能な AI 群制御基盤を構築し、現場即応性と堅牢性を高める。
- **分散協調 AI による社会実装の推進**
  集中制御型に代わり、多数の分散 AI による柔軟・冗長な判断構造を実現。輸送・災害・都市インフラ領域への実装性を高める。
- **専門家様式に基づく判断透明化と信頼性向上**
  RCT 世界モデルと OODA アーキテクチャにより判断根拠を可視化・共有し、人との協調・説明性・安全性の高い知的支援基盤を提供。
- **現場知能としての AI 性能革新**
  論理的判断と実行行動を統合した構造により、実世界での適用汎用性・実行可能性を両立し、次世代の現場対応型 AI としての革新を実現。

３．１．３．３ 既存研究に対する優位性

本研究は、完全分散型マルチエージェント AI の実機運用と、認知的世界モデルを核とする統合アーキテクチャ「MAARC」の構築を通じて、以下の観点において既存研究に対する明確な優位性を有する。

（１） 汎用的かつ再利用可能な統合知能構造の実現

意思決定と群制御を統合した AI アーキテクチャにより、汎用性・再利用性を備えた知能基盤を確立。

従来の研究は、交通制御、編隊飛行、戦略ゲームなど特定のユースケースに特化し、意思決定と群制御が別個に設計されていることが多く、判断と行動の連携性や汎用的適用が困難であった。

本研究では、OODA ループ全体（Observe-Orient-Decide-Act）を内包する知能構造を、マルチエージェント AI として分散実装。これにより、個体と群の動的連携が可能となり、応答性と適応性を同時に実現する。さらに、CAE や計算力学の抽象化・構造化・可視化手法を応用し、意思決定と群制御をタスクモデルとして再構成。これにより、知能構造を再利用可能な設計資産として蓄積できる汎用アーキテクチャを実現している。

（２） 判断根拠の可視化を可能にする認知的世界モデルの導入

RCT 世界モデルにより、AI の判断構造と根拠を人間にとって可視かつ共有可能な形で明示化。

従来の機械学習型 AI は、判断根拠がブラックボックス化されており、記号接地問題やフレーム問題の克服が困難だった。

本研究では、専門家の思考様式を抽象化した 6 要素（Reference, Context, Task, Risk, Cost, Target）による構造化空間「RCT 世界モデル」を導入。AI の判断を多次元的に構造化・可視化し、人間と直感的に共有可能な「絵図情報」として再構成する。これにより、判断プロセスが意味的に説明可能となり、AI の透明性・整合性・共有性において既存研究を凌駕する。

（３） 社会実装を見据えた信頼性・説明可能性の確保

AI の判断根拠を構造的に開示し、実運用に必要な信頼性と安全性を実装段階で担保。

従来の AI はブラックボックス的で、説明可能性やフェイルセイフ性に乏しく、社会インフラや実機応用への展開において、品質保証や倫理的妥当性（ELSI）の確保が課題となっていた。

本研究では以下の設計要素により、社会実装を前提とした信頼性を担保：

- RCT 世界モデルと絵図情報による判断根拠の可視化
- ルール・学習統合型（ハイブリッド）AI による推論の安定性と柔軟性
- モジュール設計・データモデル中心設計による冗長性とフェイルセイフ性

これにより、人間の意味的介入を許容しつつ、高信頼・高説明性の AI 知能として、防災・輸送・警備等への社会実装が現実的となる。

（４） 集中・分散構成への柔軟対応を可能にする設計

運用環境に応じて集中／分散構成を自在に切り替え可能な柔軟アーキテクチャを実現。

従来システムは、設計段階で集中型または分散型のいずれかに固定されており、構成変更や拡張が困難だった。

本研究では、モジュール単位の疎結合設計とデータモデル中心設計により、以下の柔軟な構成展開を可能とする：

- クラウド／サーバ集中型構成
- エッジ／現場分散型構成
- 両者の混在によるハイブリッド運用構成

この柔軟性により、研究開発フェーズでの集中型評価と、現場実運用での分散制御を同一アーキテクチャ上で統合でき、AI システムのライフサイクル全体を通じて優位性を発揮する。

（５） 軽量性と成長性を両立したAI基盤の構築

学習資源への依存を抑えつつ、導入初期から実用可能で長期的に進化可能なAI設計を提示。

本研究では、以下の要素の統合により、軽量かつ成長可能なAI基盤を構築している：

- **RCT 世界モデル**：任務・目的・制約を構造化した意味空間により、非構造的データ依存を低減し、高効率な認知入力を実現。
- **モジュール設計**：認識・状況理解・行動選択を機能別に分離し、任務ごとに再構成・再利用可能な設計資産として活用。
- **ハイブリッドAI**：導入初期はルールベースで即時運用を実現し、運用を通じて機械学習の適応性が段階的に成長する構造。

これにより、初期導入時の即効性と安全性、運用後期の汎化能力と柔軟性を両立し、限られた学習資源環境下でも持続的な運用が可能となる。

（６） 総括

以上のように、本研究は、AIアーキテクチャ、世界モデル、実装手法の各側面から、**分散協調性・可視性・柔軟性・信頼性・実装性・軽量性**といった根本的な課題に体系的に対応しており、既存研究を超える新たなマルチエージェント知能基盤として、実装・運用・展開において高い優位性を有している。

３．１．４ 本研究に関する関連用語および略語

本研究課題に関連する用語及び略語を、以下に示す体系で項目毎に表にまとめた。

（１）用語体系

① **研究課題**：本研究課題を説明するための用語を集約した。表 ３．１．４－１参照。
② **人工知能**：本研究課題において利用する人工知能に関する用語を集約した。表 ３．１．４－２参照。
③ **マルチエージェント**：本研究課題にて研究するマルチエージェントに関する用語を集約した。表 ３．１．４－３参照。
④ **群制御技術**：本研究課題にて研究する群制御に関する用語を集約した。表 ３．１．４－４参照。
⑤ **設計思想**：本研究課題にて準拠する設計思想に関する用語を集約した。表 ３．１．４－５参照。
⑥ **弊社製品技術用語**：本研究課題に関係する弊社システム・技術・製品に関する用語を集約した。表 ３．１．４－６参照。

（２） 略称体系

① **技術系略称**：本研究課題に関連する技術系の略語を集約した。定義は用語を参照のこと。表 ３．１．４－７参照。
② **弊社管理用略称**：弊社の管理用に通称として用いる略称を集約した。表 ３．１．４－８参照。
③ **弊社英語表記名称**：英語表記の用語を集約し再掲した。略称と混同を防ぐため補足として作成した。表 ３．１．４－９参照。

表 ３．１．４－１ 研究課題に関する用語

No.	用語	定義
1	マルチエージェント意思決定	マルチエージェント意思決定とは、複数のエージェントが動的な環境に適応しながら、所属する組織全体の目標を達成するために、それぞれが独立または協調して、意思決定する過程をいう。弊社では、分散型だけでなく、分散型に拡張可能な中央集権型の方式も含めている。
2	群制御	群制御とは、複数のエージェントが協調して目標を達成するためのロボット制御技術である。エージェント同士の相互作用を考慮して、より効率的な行動や調整を行う。群制御には、分散型制御や中央集権型制御などの種類がある。
3	群知能	群知能とは、鳥の群れやアリの共同体等の自然界の集団行動を模倣し、単純なエージェントが分散型で協調しながら全体として複雑な行動を生み出す人工知能技術である。各エージェントは単純なルールに従ってローカルに相互作用し、その結果として全体の知能的な振る舞いが創発する。鳥の群れやアリの共同体などがその例であり、人工知能やロボット工学などで応用されている。
4	物理学ベース群知能	物理学ベース群知能とは、生物学ベースのものを物理法則と計算力学を用いて再定義したものである。多数の無人機を、変化する状況に適応するよう、シミュレーションで少し先の未来を予測して誘導・協調させる制御技術である。安全保障技術研究推進制度の令和元年度の弊社研究課題において研究(先行研究１、安保研究 R1(弊社通称))を実施し、日本で初めて 20 機のスウォーム飛行を実証した。
5	自律化	自律化とは、人間の指示や介入を必要とせず、環境の変化や予測できない状況に対応しながら、自らの判断でタスクを遂行する能力を持つことをいう。自律化の要素には、センシングとデータ取得、環境認識、意思決定と行動計画、動作制御、及びフィードバック等が含まれる。弊社では、この過程を OODA で整理し、マルチエージェント AI 技術により実現を目指している。
6	OODA	OODA とは意思決定理論の一つである OODA ループに由来する。OODA ループは、Observe（観察）、Orient（情報整理）、Decide（決定）、Act（行動）の 4 つのプロセスを繰り返すことで、状況に応じた迅速な意思決定を可能にするものである。アメリカ空軍のジョン・ボイド大佐によって提唱され、元々は航空戦に臨むパイロットの意思決定を対象としていたが、作戦術・戦略レベルにも敷衍され、更にビジネスの分野でも活用されるようになった。
7	計算力学	計算力学とは、物理的な現象を記述する数理モデル（例えば、微分方程式）をコンピュータ上で解くことで、構造物の変形や応力分布、流体の流れ、熱伝導などの複雑な力学現象を解析する技術である。
8	サイバーフィジカルシステム	サイバーフィジカルシステム(CPS) とは、物理的な世界とサイバー空間を統合し、センサで取得したデータをデジタル処理し、その結果を用いて物理システムを制御するシステムである。主な要素は、センサとアクチュエーターによるデータ取得と実行、リアルタイムデータ処理、通信ネットワーク、そして物理システムのデジタルモデル（デジタルツイン）である。
9	デジタルツイン	デジタルツインとは、実世界の状況と行動主体の任務や挙動を仮想化(デジタル化)し、コンピュータ上の仮想世界(サイバー世界)に再現したデジタルモデル及びそのシミュレーション環境のことをいう。
10	シミュレーシ	シミュレーションとは、現実のシステムの動作規則や現象の物理法則をモデル化し、コンピュータなど

	ョン	を用いてその挙動を再現・予測する手法である。ユーザは、プリ処理にて対象をモデル化し、ポスト処理にて結果を評価する。解析処理中にユーザとの相互作用は行われない。弊社の MAS 環境(ACS-VTP Plant)は、ゲーム要素を含み、リアルタイム処理中にユーザとの相互作用が可能である。
11	ゲーム	ゲームとは、娯楽や競技、学習を目的として行われる活動やコンテンツのことをいう。ゲームは、事前にルールが設定された状況で、プレイヤが、目標に向けてプレイヤ間の競争・協力・挑戦を伴うプレイをし、プレイヤに結果・報酬・得点等をフィードバックし、楽しみや満足感を提供することを目的としている。弊社の MAS 環境(ACS-VTP Plant)は、シミュレーション要素を含み、ユーザが事前にルール設定(状況のモデル化)が可能である。
12	逐次意思決定問題	逐次意思決定問題（Sequential Decision Problem）とは、複数の意思決定のステップがある問題で、それぞれのステップで選択可能なアクションが複数ある場合に、最適な行動を決定するための問題である。逐次意思決定問題は、マルコフ決定過程（MDP）としてモデル化することができる。
13	マルコフ決定過程	マルコフ決定過程（Markov Decision Process, MDP）は、現在の状態と選択可能なアクションに対する報酬が与えられた、確率的な意思決定問題である。確率的な状態遷移と報酬の受け取りを伴う意思決定問題を扱うための数理モデルとして表現できる。
14	マルコフゲーム	マルコフゲーム（Markov Game）は、複数のエージェントが環境と相互作用する、マルコフ決定過程の一種である多人数ゲームである。
15	完全情報ゲーム	完全情報ゲームとは、全ての意思決定点において、これまでに取られた行動や実現した状態に関する情報が全てのプレイヤに与えられている展開型ゲームのことをいう。
16	不完全情報ゲーム	不完全情報ゲームとは、プレイする上で重要な情報の一部がプレイヤに隠されているゲームのことをいう。未知要素が常に動的に存在するのが特徴である。競合型の場合、ゲーム開始時はお互いに相手の情報が未知である。配下エージェントを使って観測することで状況が既知になる。

表 ３．１．４-２　人工知能に関する用語

No.	用語	定義
1	AI(人工知能)	AI(人工知能)とは、入力データを何らかの処理をして知的な結果を出力するプログラムである。歴史的に、機械学習を使用するもの以外にも、ルールベースなどの他の技術を使用するものが含まれ得る。しかし近年では、急速に発展している生成 AI、機械学習を使用するものを念頭に置かれていることが多い。本研究では、後者を採用するが、ルールベースのプログラムを最適化するものも含むものとする。
2	ドメインシフト問題	ドメインシフト問題とは、学習データと運用時（推論時）のデータの分布が一致せず、出力した回答の精度に影響が生じる現象をいう。課題解決に即したターゲット集団のデータを用いて学習を行わなければ精度が低下する。
3	Sim2Real 問題	Sim2Real 問題とは、シミュレーションを用いて訓練した AI エージェントが実環境でうまく機能させることが困難となる現象をいう。シミュレータのサイバー世界と実世界のギャップによって AI モデルの精度が下がる。ドメインシフト問題の一形態である。

表 ３．１．４-３　マルチエージェントに関する用語

No.	用語	定義
1	エージェント	エージェントとは、自ら判断し行動する知的な主体のことをいう。その型式には、コンピューターシステムとして実現したもの、及びその支援を受けて行動する人も含む。また、個体だけでなく、スウォーム、チーム、グループ等の小集団等も含まれる。人工知能の学術領域のひとつである。
2	マルチエージェント	マルチエージェントとは、複数のエージェントが関与する状況、集団、システムをいう。
3	マルチエージェントシステム	マルチエージェントシステム(MAS)とは、複数のエージェントの組織的な行動によって大域的な機能を発揮し、全体の目標を達成するために設計されたシステムである。MAS はエージェントの集合体であり、その構造や機能を管理するための枠組みや規則が存在する。
4	マルチエージェント技術	マルチエージェント技術とは、全体の目標の達成に向けて、複数エージェントを組織的に協調させて大域的な機能を発現させる技術のことをいう。
5	マルチエージェント AI	マルチエージェント AI(MA-AI)とは、全体の目標の達成に向けて、複数エージェントを連携させて大域的な機能を発現させる意思決定を行う AI のことをいう。
6	マルチエージェントロボティクス	マルチエージェントロボティクスとは、全体の任務目的の達成に向けて、複数エージェントやスウォームを連携させて大域的な機能を発現させる意思決定に基づいて群制御を行うロボット技術のことをいう。
7	マルチエージェントシミュレーション	マルチエージェントシミュレーション(MAS)とは、複数のエージェント(個体やスウォーム)が互いに影響を及ぼしあう複雑な現象を分析する仮想実験のことをいう。弊社の MAS 環境(ACS-VTP Plant)は、シミュレーションのようにユーザがシナリオをモデル化できる汎用性の高いゲーム環境である。
8	マルチエージェント制御	マルチエージェント制御(MAC)とは、群制御と同義である。

表 ３．１．４-４　群制御に関する用語

No.	用語	定義
1	スウォーム	スウォーム（swarm）とは、物理的に一団として移動させたり、組織的に行動させることにより機能を発揮する UxV 群のことをいう。
2	物理的スウォーム	物理的スウォームとは、物理的に集団として移動することにより機能を発揮する UxV 群のことをいう。
3	組織的スウォ	組織的スウォームとは、独立または小集団で組織的に行動することにより機能を発揮する UxV 群のこと

	ーム	をいう。
4	ヒューマンスウォームインタラクション	ヒューマンスウォームインタラクション(HSI)とは、人とスウォーム間の情報のやり取り等の相互作用に関する技術をいう。
5	群制御（弊社技術）	弊社の群制御は、多数のエージェントやスウォームに対する経路生成、交通空域管制、及び誘導制御等を行う広域群制御、並びに密集するエージェントやスウォームに対する誘導制御及び協調制御等の局所群制御のことをいう。
6	広域群制御	広域群制御とは、多数のエージェントやスウォームについて実施する経路生成、交通空域管制、及び誘導制御のことをいう。組織的スウォームを実現する技術である。
7	局所群制御	局所群制御とは、密集するエージェントやスウォームについて実施する誘導制御及び協調制御のことをいう。物理的スウォームを実現する技術である。
8	UxV	UxV とは、Unmanned x Vehicle の略で、無人機の総称である。「x」には運用環境を示す符号が当てられ、x=G は Ground(陸上)、A が Airial(航空)、U が Under Water(水中)、S が Surface(海上)を意味する。
9	UAV	UAV とは、Unmanned Aerial Vehicle の略で、航空無人機のことをいう。
10	UGV	UGV とは、Unmanned Ground Vehicle の略で、陸上無人機のことをいう。
11	AGV	AGV とは、Automatic Guided Vehicle の略で、無人搬送車のことをいう。AGV は、建屋内の床に設置した磁気テープ、ランドマーク、または高周波信号線等により走行ルートを指定し、ルートに沿って荷物を搬送する。
12	AMR	AMR とは、Autonomous Mobile Robot の略で、自律走行搬送ロボット・自律移動ロボットのことをいう。AMR には SLAM（Simultaneous Localization and Mapping）という技術が用いられ、自身の位置と周辺物体の位置を把握しながら目的地までの地図を自動で生成することができる。

表 ３．１．４-５　設計思想に関する用語

No.	用語	定義
1	ソフトウェアファースト設計	ソフトウェアファースト設計とは、システム製品の開発において、ソフトウェアによって実現すべき機能・性能を最初に設計し、そのソフトウェアの機能を実現するハードウェアを設計・選定する設計思想である。この設計思想を実現する手段として、機械工学ではモジュール化設計、ソフトウェア工学ではオブジェクト指向がある。この両者は、独立性、交換性、再利用性、及び保守性等の向上を狙っている点が共通している。また、開発手法として、要素技術の評価検証を小要素、大要素、全体と段階的に進めるビルディングブロックアプローチがある。
2	モジュール化設計	モジュール化設計(モジュラーデザイン, Modular Design)は、機械や製品を機能的な単位（モジュール）に分割して設計する方法である。各モジュールは独立して機能し、他のモジュールと組み合わせることで全体としての機能を実現する。これにより、製品の組み立てや製造、メンテナンスが容易になり、柔軟性やカスタマイズ性が向上する。航空機の開発手法として 1950 年代から発展してきた。
3	オブジェクト指向	オブジェクト指向（Object-Oriented Programming、OOP）は、ソフトウェアの設計と開発のための思想である。オブジェクトは、 実世界の対象や概念を関連するデータ(属性)と処理(メソッド)を一つにモデル化し、外から内部を見えないようカプセル化している。クラスはそのひな形となります。その目的は、オブジェクトを利用することで、ソフトウェアの設計をより理解しやすく、再利用しやすくし、保守や拡張を容易にすることである。
4	ビルディングブロックアプローチ	ビルディングブロックアプローチ（Building Block Approach）は、システムを構築する際に、基本的な構成要素や部品（ビルディングブロック）を組み合わせることで、全体を構築する手法です。複雑なシステムを簡単に管理・設計できるようにするためのものです。航空機の開発手法として 1950 年代から用いられてきた。
5	フェイルセイフ設計	フェイルセイフ設計とは、システムや機器が故障や誤動作をした際に、安全性を確保するための設計思想である。この設計思想では、万が一システムが正常に動作しなくなった場合でも、危険な状況や損害を最小限に抑えることを目指している。
6	損傷許容性	損傷許容性（Damage Tolerance）とは、構造物や材料がある程度の損傷を受けても、直ちに破壊や重大な故障に至らず、引き続き安全に機能を維持できる設計の考え方や特性のことである。このアプローチは、特に航空宇宙、橋梁、建築物などの安全性が非常に重要な分野で広く採用されている。
7	環境	環境とは、特定のシステムが動作するための設定や条件、またはそのシステムの利用条件をいう。環境は、ハードウェア、オペレーティングシステム、ミドルウェア、ネットワークなどの運用設定などを含むことがある。環境は基盤の上で構築され、その上でソフトウェアが動作する。例：開発環境: 開発者がコードを書いたりデバッグしたりするための設定（IDE、ローカルサーバーなど）。本番環境: 最終製品がユーザに提供される環境（本番サーバ、ユーザが実際に使うシステム設定など）。
8	基盤	基盤とは、システムを支えるための基礎的なハードウェアやソフトウェアの構造、リソースのことをいう。基盤は物理的および論理的な支えを提供し、環境はその基盤の上でどのようにソフトウェアが利用されるかを定義する。例:サーバーインフラストラクチャ: 物理的なサーバや仮想サーバ、ネットワーク設備。クラウド基盤: クラウドサービスプロバイダーが提供するコンピューティングリソースやストレージ、データベースサービス。
9	アプリケーション	単独で動作するソフトウェアのことをいう。
10	ソルバ	入力データに基づいて数理モデルを解析し、問題を解くソフトウェアのことをいう。
11	モジュール	他のシステムやアプリケーションに組み込まれ動作するソフトウェアのことをいう。

表 ３．１．４-６　弊社製品技術用語

No.	用語	定義
1	OODA群制御AIシステム	弊社システム名称。本システムは、マルチエージェントシステムの一種である。本システムは、OODA群制御AIを搭載し、無人機等の配下エージェントを用いて、組織的な意思決定と群制御のOODAループを半自律的に行うシステムである。本システムは、計算力学とゲームAIを応用した階層型アーキテクチャにより、意思決定の高速化、学習の効率化、判断根拠の見える化を実現する。
2	空間情報(離散化)データモデル基盤	弊社システムの構成要素名称。空間情報(離散化)データモデル基盤は、AIが、サイバー世界で空間情報を認知・思考し、実世界で無人機を群制御するためのデータ連携・機能統合基盤である。IS-Physicsモデルに従って、デジタル化された任務空間や移動経路、及びエージェントの動作やタスクがサイバー世界に生成される。離散化には、有限要素法、格子法、粒子法等の計算力学の手法を応用している。
3	OODA 群制御AI	弊社AIモジュール名称。OODA理論に基づき、無人機や人等の配下エージェントの組織的な意思決定と群制御を行うAIモジュールである。その役割は、配下エージェントの観測情報を処理し、タスク生成、経路生成、交通制御を自律的に行うことである。
4	LGソルバ	OODA群制御AIを構成するルールベースAIの名称。LGはロジックの略称。計算力学を応用したロジックベースの群制御アルゴリズムである。
5	タスクソルバ	弊社プログラム名称。上位タスクに従い、担当エージェントや目的地を選定する。LGソルバの一機能を担うソフトウェアモジュールである。
6	トラフィックソルバ	弊社プログラム名称。経路生成、交通制御・空域管制、移動体の走行制御を担当するコアモジュールである。LGソルバの一機能を担うソフトウェアモジュールである。
7	マップソルバ	弊社プログラム名称。AI意思決定・群制御に必要な整理情報を、観測情報や応答情報から生成する。LGソルバの一機能を担うソフトウェアモジュールである。
8	AIソルバ	OODA群制御AIを構成する機械学習以降のAIの名称。AIソルバは、AIモデルを用いて、入力データを処理し、結果データを出力するソフトウェアモジュールのこと。LGソルバの設計諸元を動的に最適化するLG支援型、及びLGソルバの機能を代替するLG置換型のAIがある。
9	LG支援型AI	弊社AIの名称。LG支援型AIは、LGソルバの設計諸元を動的に最適化するAIモデルのこと。モデルベース強化学習(MBRL)の手法を応用している。
10	LG置換型AI	弊社AIの名称。LG置換型AIは、LGソルバの全部または一部機能を代替するAIモデルのこと。
11	MAARP	弊社製品名称。MAARP（Multi-Agent AI & Robotics Platform）は、マルチエージェントAI（OODA群制御AIを標準搭載）による無人機等エージェントの群制御、及びそのAI設計・任務設計の評価や最適化を行う運用・研究開発支援プラットフォームである。MAARPは、任務シナリオのデジタルモデリング、シミュレーションによる仮想テスト、CPS（サイバーフィジカルシステム）による実機テスト環境を提供する。ユーザのAI研究、任務設計の効率化、実機運用時の意思決定を支援する。その構成は、ACS、VTP-Plant、スウォーム通信IF、及び標準無人機システムとなる。本研究では、OODA群制御AIはACSに搭載され、仮想テストや実機テストによるAI研究をMAARPを用いて行う。
12	ACS	弊社システム名称。アプリケーション「VTP(Virtual Test Platform)」を制御モードで起動した時の名称である。エージェント制御システムの英名「Agent Control System」に由来する。OODA群制御AIを標準搭載し配下エージェントを制御する。また、顧客のMA-AIも実装可能である。
13	VTP Plant	弊社システム名称。アプリケーション「VTP(Virtual Test Platform)」を制御対象(Plant)モードで起動した時の名称である。ACSと連携し、マルチエージェントシミュレーションによる仮想テスト機能、及びCPSによる実環境テスト機能を発揮する。
14	AI SLPF	弊社システム名称。AI自己学習プラットフォームの英名「AI Self Learning Platform」に由来する。ACS及びVTP Plantと連携し、自動的に機械学習を行う。
15	HATS	第三者製品・技術等の名称。株式会社キビテクの遠隔制御・監視システムの名称。
16	IS-Physicsモデル	弊社システムのデータモデルの総称。IS-Physicsモデルは、物理世界(実世界)におけるマルチエージェントの任務環境、動作、タスク等を表現するデジタルモデルのこと。本モデル化規約に従って作成した入力データにより、サイバー世界に実世界のデジタルモデルが再現される。ISは、iSwarming及びInter Swarmの略称である。
17	MB	弊社データモデル名称。Moving Body の略称。移動体のことをいう。
18	Path	弊社データモデル名称。トラフィックソルバの経路生成機能が出力する経路情報のことをいう。
19	PMT	弊社データモデル名称。トラフィックソルバの交通制御機能が出力する移動許可情報のことをいう。
20	RCT	弊社データモデル名称。RCT情報は、AIが、判断材料として参照し、意思決定を行うための情報である。エージェントの観測データが、任務に応じたRisk、Cost、Targetの各情報に分類される。
21	インタースウォーム	弊社技術構想の名称。インターネットのスウォーム版。インターネットの様にスウォーム間のデータ連携を促進するだけでなく、個々のスウォームがAIの認知・思考基盤を共用し、個々のスウォームが仲間の思考を推測しながら組織的な阿吽の呼吸の行動を実現できる基盤のこと。
22	CP-Game	弊社技術構想の名称。Cyber Physical-Gameに由来する。通常、ゲームはサイバー世界に閉じている。CP-Gameとは、弊社CPS・デジタルツイン技術によりサイバー世界と実世界を連接させたリアルタイムゲームを言う。インタースウォームの研究を行うための手段である。
23	CP-MAS	弊社技術構想の名称。Cyber Physical-Multi Agent Simulationに由来する。通常、シミュレーションはサイバー世界に閉じている。CP-MASとは、弊社CPS・デジタルツイン技術によりサイバー世界と実世界を連接させたリアルタイムシミュレーションを言う。インタースウォームの研究を行うための手段である。

表 ３．１．４－７　技術系略語

No.	略語	定義
1	CP	Cyber Physical の略称。サイバー世界とフィジカル世界のこと。
2	FB	Feed Back の略称。応答のこと。
3	HSI-IF	HSI は、Human Swarm Interaction の略称。IF は、Interface の略称で、人が視認し操作できる装置のこと。
4	RL	Reinforcement Learning の略称。強化学習のこと。
5	MA	Multi-Agent の略称。マルチエージェントのこと。
6	MBRL	Model Base Reinforcement Learning の略称。モデルベース強化学習のこと。
7	MARL	Multi Agent Reinforcement Learning の略称。マルチエージェント強化学習のこと。
8	MMF	Memory Mapped File の略称。コンピュータのメモリをファイルの様に使う技術のこと。

表 ３．１．４－８　弊社管理用略語

No.	略語	定義
1	先行研究 1	令和元年度に防衛装備庁の安全保障技術研究推進制度に採択された「機械学習と物理学ベース群知能による状況適応型群制御の研究」を指す。
2	先行研究 2	先行研究 1 の課題へ対応し社会実装を進めるため、顧客プロジェクトで実施した「工場の生産工程における AGV 搬送の制御アルゴリズム創発・デジタルツイン対応プロジェクト」を指す。
3	安保研究	安全保障技術研究推進制度の弊社社内呼称。末尾に和暦の略称 R1, R5 等をつけた場合は、当該年度の弊社研究課題を指す。
4	ANPOR1	安全保障技術研究推進制度の令和元年度の弊社研究課題の弊社社内呼称。
5	ANPOR5	安全保障技術研究推進制度の令和 5 年度の弊社研究課題の弊社社内呼称。

表 ３．１．４－９　弊社英語表記用語（再掲・抜粋）

No.	略語	定義
1	ACS	弊社製品の名称。Agent Control System に由来する。
2	VTP Plant	弊社製品の名称。Virtual Test Platform for Plant に由来する。
3	AI SLPF	弊社製品の名称。AI Self Learning Platform に由来する。
4	LG ソルバ	弊社製品の名称。LG はロジックの略称。
5	HATS	第三者製品・技術等の名称。株式会社キビテクの遠隔制御・監視システムの名称。
6	IS-Physics	弊社データモデルの総称。IS は、iSwarming®、InterSwarm に由来する。Physics は物理世界をモデル化することに由来する。
7	MB	弊社データモデルの名称。Moving Body(移動体)に由来する。
8	RCT	弊社データモデルの名称。Risk・Cost・Target に由来する。
9	CP-Game	弊社技術構想の名称。Cyber Physical-Game に由来する。
10	CP-MAS	弊社技術構想の名称。Cyber Physical-Multi Agent Simulation に由来する。

３．２　実施項目①OODA群制御AIアーキテクチャの研究

３．２．１ 本研究課題に関する概念整理

３．２．１．１ マルチエージェント逐次意思決定問題

本研究の対象問題は、未知環境、即ち競合型の不完全情報ゲームの逐次意思決定問題である。意思決定の階層は、図　３．２．１－１に示すように、戦略レベル、戦術レベル、実行レベルに階層化される。階層は上下関係（親子関係）を成し、上位は、下位の状態や観測情報に基づいて、任務目的を達成するように意思決定を行い、下位に命令を下す。意思決定のプロセスは、異なる階層でも類似性が高く、OODAループで定式化できる。

この意思決定の階層構造の上層は情報を主に扱う情報領域の問題、下層は情報に加え物理も扱う物理領域の問題となる。本研究では、将来の指揮統制には無人機が含まれるため、情報領域から物理領域に渡るマルチエージェント・逐次意思決定問題に対応する必要がある。

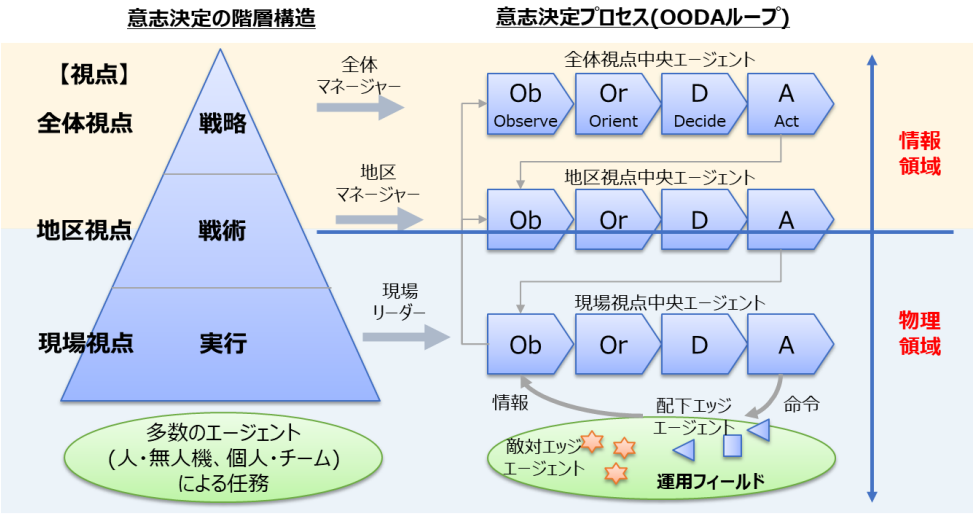

図　３．２．１－１　マルチエージェント・逐次意思決定問題の用語・概念の構造

３．２．１．２ 階層型逐次意思決定の構造

本研究における実機を対象としたマルチエージェント技術の要素技術の体系を図　３．２．１－２に示す。検討では、意思決定の階層の視点から、機能、要素技術、及び学術領域を体系的に整理した。以下にその概要を示す。また、マルチエージェントの意志決定や群制御に関する機能一覧を表　３．２．１－１に示す。

（本研究のマルチエージェント技術の特徴）

- 学術的な視点：オペレーションズ リサーチ（OR）の情報領域から制御工学や機械工学の物理領域に至る。
- 任務や業務の視点：意志決定主体の階層や視点に応じて、優先すべき事項が異なる。階層の上位は、情報領域の問題を主に扱い、最適化の目的は効率性や生産性などの性能向上に着目される。階層の下位は、物理領域の問題となり、安全第一を最優先する必要がある。

（意思決定の階層構造）

- 意思決定の階層構造は階層毎に相似である。
- 上位エージェントは、担当する領域の意思決定を行い、「中央」、「中央制御局（CCS, Central Control Station）」、「親」「リーダー」等と呼称される。
- 下位エージェントは、上位意志決定を実行する主体であり、配下エッジエージェント、単にエージェントと呼称される。配下エッジエージェントは、階層の位置付けに応じて、人・無人機、個体・集団が単位となる。

（要件）

- ORや制御工学に渡るマルチエージェントAI研究に対応できるように、階層型意志決定の構造や処理手順をモデル化しその処理を実行できること。
- AI研究のため、IS-Physics形式に準拠したモデルを使うAIは、本システムに組み込んでシミュレーションによる評価や学習を実行できること。
- 階層の視点に応じて、最適化の目的関数や制約条件、強化学習の評価関数を、情報領域や物理領域の指標(性能向上と安全確保等)を考慮できること。

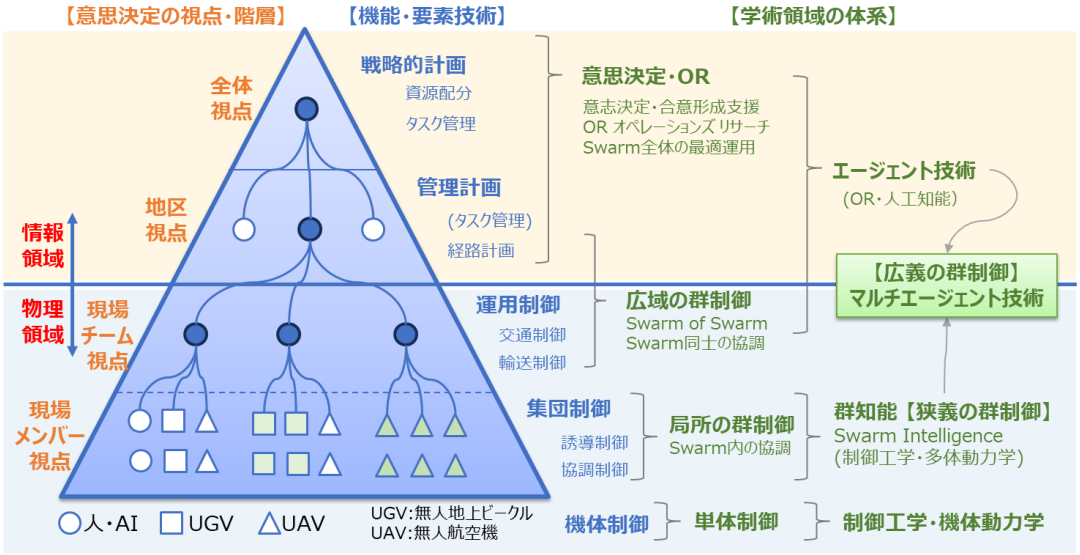

図　３．２．１－２　マルチエージェント意思決定・群制御の構造と技術俯瞰図

資料「日本 OR 学会 OR 事典 Wiki 図１：アンソニーの管理階層」、及び資料「JST CDRS(科学技術振興機構 研究開発戦略センター) 俯瞰ワークショップ報告書 「エージェント技術」」を参考に弊社作成。各階層間の連携を担う「通信技術」は記載を省略する。

表　３．２．１－１　マルチエージェント意思決定と群制御の機能一覧

マルチエージェント技術（意思決定支援・群制御）				領域	最適化	学術分野		
範囲	階層	機能	概要	種類	優先順位	OR	MA制御	機体制御
マクロ	戦略的計画	資源配分	配下エージェント(人・無人機・設備)の構成の最適化	情報領域	効率性	意思決定支援		
		タスク管理	上位命令に対応するためのタスク選定と担当選定の最適化	情報領域	効率性	意思決定支援		
	管理制御	経路計画	担当毎に経路を最適化。渋滞やリスクも考慮	情報領域	効率性	意思決定支援	広域 群制御	
ミクロ	運用制御	輸送制御	交通流を可視化。広域的な衝突回避無し。衝突回避は局所で対応。	情報領域	効率性	意思決定支援	広域 群制御	
		交通制御	交通状況に応じた移動許可制御を行う。衝突回避有り。	物理領域	安全性＞効率性		広域 群制御	
超ミクロ(ナノ)	集団制御	誘導制御	ユニット代表または全機を誘導(ウェイポイント・流れ場)	物理領域	安全性		局所 群制御	
		協調制御	ユニットの集団形成と機体間の衝突回避の協調制御	物理領域	安全性		局所 群制御	
	機体制御	運動制御	機体やユニット単位の運動制御	物理領域	安全性			運動制御
		フィードバック	配下エージェントの状態を中央またはエッジ間で共有	物理領域	―			フィードバック
		センシング	センシング情報を中央またはエッジ間で共有	物理領域	―			センシング

資料「日本 OR 学会 OR 事典 Wiki 図１：アンソニーの管理階層」、及び資料「JST CDRS(科学技術振興機構 研究開発戦略センター) 俯瞰ワークショップ報告書 「エージェント技術」」を参考に弊社作成。

３．２．１．３ 競合型 不完全情報ゲーム

マルチエージェントの逐次意思決定問題を解くAIは、表 ３．２．１－２に示すように、未知要素を含まない完全情報ゲームだけでなく、未知要素を含むマルコフ決定過程の不完全情報ゲームに対応できる必要がある。

表 ３．２．１－２ 完全情報ゲームと不完全情報ゲームのシステム要求比較

	完全情報ゲーム	競合型 不完全情報ゲーム
定義	全ての意思決定点において、これまでに取られた行動や実現した状態に関する情報が全てのプレイヤに与えられている展開型ゲーム。	プレイする上で重要な情報の一部がプレイヤに隠されているゲーム。未知要素が常に動的に存在するのが特徴である。競合型の場合、ゲーム開始時はお互いに相手の情報が未知である。配下エージェントを使って観測することで状況が機知になる。
例	AGV 搬送：管理された環境で、上位システムのオーダーに従い、任務を遂行する。 未知要素は、作業員の予期しない侵入やAGV 故障等がある。	警備ゲーム： 警備側と不審者側に分かれ、警備側は不審者を警戒し対処する。 戦略ゲーム： 敵・味方に分かれて勝利を目指す。相手の行動や意図が未知の要素となる。
構成	プレイヤ１名：ACS ゲーム環境：VTP Plant	プレイヤ２名以上：ACS(i) i=1,2… ゲーム環境：VTP Plant
システム要求	ACS は工場搬送工程の管理者としてプレイする。ACS のマップは VTP Plant と同じマップと状態情報を持つ。ACS は自動的に配下エージェントを制御し任務を遂行する。 VTP Plant は ACS と対に存在し、搬送工程や人誤侵入等の障害を再現する。VTP Plant のマップは ACS と同じマップとなる。 空間情報データモデルは、ACS と VTP Plant は同じ構成のマップモデルを保持する。	ACS は、自チームと相手チームに相当する ACS が複数存在する。各チームの ACS のマップは、配下情報と配下エージェントの観測情報が表示される。観測した部分が未知から既知となり、相手に勝つようにゲームを進める。 VTP Plant は、プレイヤ役を担う ACS 複数がアクセスできるようにする必要がある。また、審判の視点で、マップ上に全プレイヤの情報が表示される。無人機が未知オブジェクトを観測したときは上位の ACS に情報を送る。 空間情報データモデルは、ACS と VTP Plant で役割に応じた構成のマップモデルを保持する。
参照	図 ３．２．１－３	図 ３．２．１－４

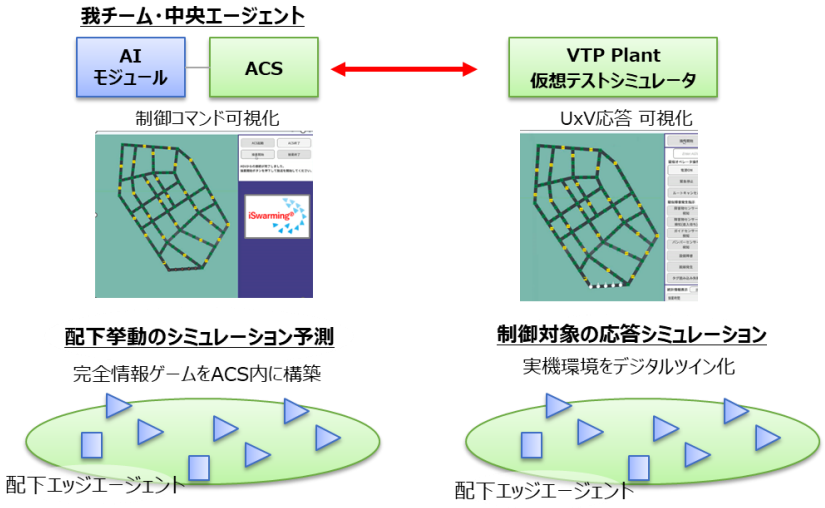

図 ３．２．１－３ 完全情報ゲーム対応の概念図

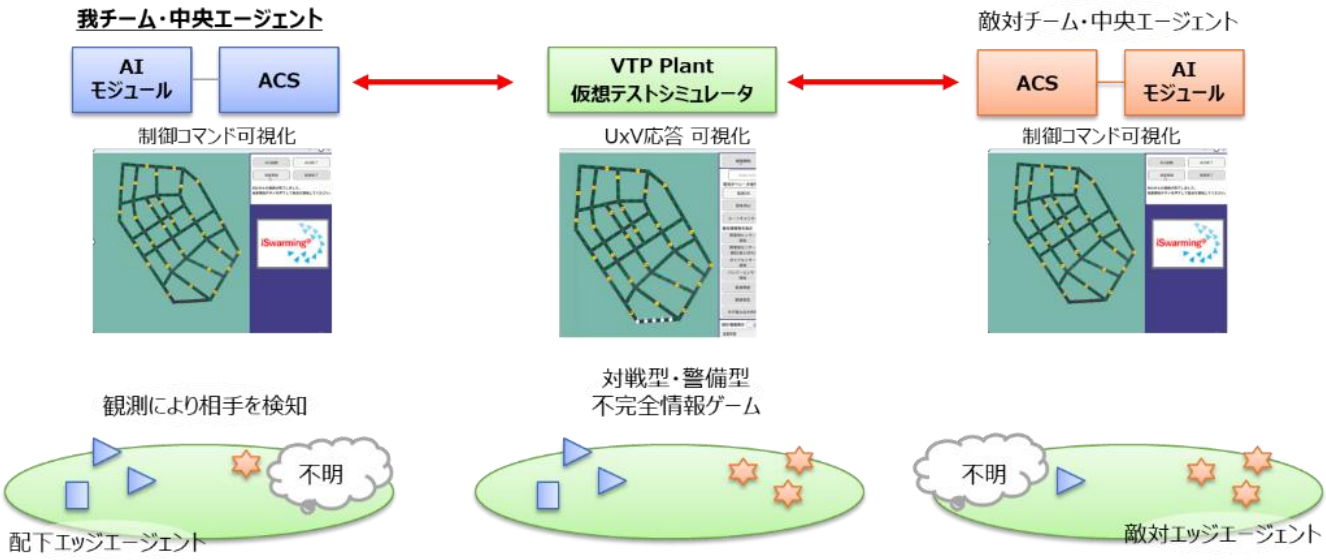

図　３．２．１－４　競合型の不完全情報ゲーム対応の概念図

３．２．２ 既存研究の整理

３．２．２．１ 整理の観点

無人機群運用における意思決定と群制御の自律化・分散化・汎用化に関する技術について調査整理した。調査した文献を本項末尾の「(参考文献)」に示す。

はじめに着目する研究事例を示す。次に、現在の問題、研究開発の潮流を、JST CRDS の AI・ロボティクス領域の報告書を踏まえて整理した。最後に、意思決定と群制御の統合自律化の観点から、AI の身体性獲得のアプローチとして注目されている二重過程理論と世界モデルを整理した。

その結果、二重過程理論と世界モデルの帰納型アプローチに対して、弊社の「RCT-OODA 群制御 AI アーキテクチャ」は、論理性や信頼性の課題に対応できる帰納型・演繹型の複合アプローチであると位置づけられることが分かった。

３．２．２．２ 研究事例

米国 DARPA は OFFSET や ASTARTE 等のプログラムにより、無人機群制御やリアルタイム空域管制の先進研究を推進している。Google DeepMind も、戦略ゲームを用いたマルチエージェント AI の研究を進め、仮想空間での集団知能の高度化を実現している。

さらに「Gemini Robotics」など、AI(論理世界)とロボティクス(物理世界)の融合が進展しており、AI の実環境適用が次のフェーズに移りつつある。このように、意思決定(論理世界)と実行(物理世界)を垂直統合するアーキテクチャは、今後の AI 実装における基盤技術として、国際的に注目されている。

図　３．２．２－１　画以外の既存研究の例

３．２．２．３ 現在の問題、 研究開発の潮流、対応へのアプローチ

JST CRDS の AI・ロボティクスに関する報告書を参考に、課題認識、現行 AI の本質的問題、研究の方向性、対応アプローチ、AI 研究の２大潮流について整理した。

（１） 課題認識

近年、基盤モデル・生成 AI が示す高度な知的挙動は、既存の深層学習技術のみでは説明が困難であり、その動作原理と性能発現の仕組みを理論的に解明することが重要課題である。これは、AI の信頼性・制御性の根本に係わる問題であり、新たな原理とアーキテクチャの探索が求められている。

（２） 現行 AI の本質的問題

- **資源効率性**：学習に膨大なデータ・計算資源・電力を要し、コストや環境負荷が極めて高い。
- **身体性(実世界操作)**：仮想的な学習に基づいており、動的・個別的な実世界への適応が困難。
- **論理性**：予測重視の確率モデルであり、論理構築や複雑なタスク分解に不向き。

- **信頼性・安全性**：ブラックボックス的性質が強く、出力の妥当性や一貫性を保証できない。

（３） 研究の方向性

次世代 AI モデルの研究は、単なる性能向上から脱却し、**知能の原理的解明**と**構成論的再設計**を重視する方向に転換しつつある。その中で、我々は、「意思決定と群制御の統合」は、複雑環境における多主体協調と適応的判断の両立を目指す重要な研究軸であると考えている。

（４） 対応アプローチと着想源

人間の知能のメカニズムは、新原理・アーキテクチャ構築の有力な着想源であり、**脳科学・認知科学・発達科学・心理学・行動経済学**などの知見が活用されている。特に、**二重過程理論**(直感的処理と熟慮的処理の併存、次ページ参照)や**予測符号化理論**(予測と誤差最小化による知覚と行動のモデル)に基づく AI モデルが試作段階に入りつつある。

（５） AI 研究の２大潮流

- 上記の本質的問題と研究の方向性、対応アプローチは、次の２大潮流に再構成されている。
  - ✧ **潮流１：第４世代 AI**
  - ✧ **潮流２：信頼される AI**
- 現行 AI の本質的問題は、潮流１と潮流２の課題として以下のように再構成されている
  - ✧ **潮流１「第４世代 AI」の課題**
    - **学習資源の過大要求**：大量の学習データと計算資源を必要とし、構築・運用コストが高い。
    - **汎化能力の限界**：学習データ範囲外への適応や、未知環境への柔軟な対応が困難。
    - **意味理解と論理推論の未成熟**：深層学習はパターン認識には優れるが、文脈理解や因果推論など高次知能の処理ができない。
    - **記号接地・フレーム問題の未解決**：言語・記号と知覚・行動との接続、予測困難な変化への柔軟対応が構造的に困難。
  - ✧ **潮流２「信頼される AI」の課題**
    - **信頼される AI の課題**
    - **ブラックボックス性**：深層学習を中心とした AI の判断根拠が不透明であり、説明責任が果たせない。
    - **品質保証の困難さ**：機械学習の帰納型手法は 100%保証が困難であり、安全性や信頼性を確保する仕組みが未整備。
    - **社会的信頼の獲得不足**：技術的信頼性のみでは不十分で、ユーザーや社会が「信じられる」AI であるための受容性確保が課題。
    - **ガイドラインの定着不足**：QA4AI や AIQM などの品質管理ガイドラインは存在するが、現場での運用・社会受容の面で整備が不十分。
- 課題への対応方針は、潮流１と潮流２で以下のように再構成されている。このうち、★印を付した項目が、弊社の対応方針と合致している。
  - ✧ **第４世代 AI の対応方針**
    - **二重過程モデルの導入★**：System1（即応的・直感的）と System2（熟慮的・論理的）を併せ持つ構成による認知機能の模倣。
    - **予測誤差最小化原理の活用★**：脳科学にもとづく認知モデルを導入し、環境との相互作用において期待と現実のズレを最小化。
    - **自己組織化・発達知能の重視★**：固定的な設計でなく、発達や環境変化に応じて柔軟に構造を変える創発的 AI の追求。
    - **身体性と環境適応性の強化★**：センサ・運動系との統合による実世界対応力の向

上。

✧ **信頼される AI の対応方針**

- **帰納型と演繹型の融合★：**機械学習（帰納型）とルールベース（演繹型）のハイブリッド設計により、安全性と柔軟性の両立を図る。
- **Safe Learning 設計の導入★：**演繹的に安全性を保証した「セーフティエンベロープ」の範囲内で、帰納型 AI を活用する方法を採用する。
- **説明可能性の確保（XAI）★：**ユーザーが AI の動作や判断過程を理解できるようにし、安心感・納得感を支援。
- **第三者認証・制度的枠組みとの連携：**AI 品質を評価・保証するための標準化や第三者機関による評価体制の整備。

３．２．２．４ 二重過程理論(Dual Process Theory)

AI(論理世界)と制御(物理世界)の統合という観点から、知覚・運動系 AI と言語・知識系 AI の統合、それらが構成する即応的ループと熟考的ループの情報の流れの統合について着目した。

人間の脳には、深層学習・強化学習に相当するような、経験に基づいた即応的な情報処理を担う部分だけでなく、ある種抽象化されたモデル・知識を参照した熟考的な情報処理を担う部分が存在すると考えられている。行動経済学で有名な **Daniel Kahneman** は、著書「ファスト&スロー」において、人間の知能（意思決定システム）には二つの側面があるとし、反応の早い即応的知能をシステム 1、それに比べると反応が遅い熟考的知能をシステム 2 と呼んだ。Yoshua Bengio の「From System 1 Deep Learning to System 2 Deep Learning」では、深層学習はシステム 1 に相当し、将来の方向性はシステム 2 も深層学習になると示唆している。国内でも松尾豊が「知能の 2 階建てアーキテクチャ」というモデルを発表している。システム 1 に相当する 1 階部分を動物 OS、システム 2 に相当する 2 階部分を言語アプリと呼び、その二つをつなぐところに世界モデルを位置付けた。国内の人工知能学会全国大会において、世界モデルやシステム 1＋2 融合に関する研究は特に活発な発表・議論が行われているトピックになっている。

３．２．２．５ 世界モデル

人間は外界に関する限られた知覚情報から脳内に外界のモデルを作り、そのモデルを用いたシミュレーションを意思決定や行動に使っていると考えられる。このモデルは「内部モデル」「力学モデル」と呼ばれることもあるが、AI 分野では「世界モデル」（World Models）という呼び方が主流である。　世界モデルは、知覚系と運動系の即応的ループと、言語・知識系まで含めた熟考的ループという 2 タイプのうち、即応的ループの中に位置付けられ、無意識的・反射的な行動にも作用すると考えられている。

３．２．２．６ 参考文献

（研究事例）

- DARPA OFFSET, https://www.darpa.mil/program/offensive-swarm-enabled-tactics
- DARPA ASTART, https://www.darpa.mil/news-events/2023-02-23
- DeepMind AlphaStar, https://deepmind.google/discover/blog/alphastar-mastering-the-real-time-strategy-game-starcraft-ii/
- Gemini Robotics, https://blog.google/intl/ja-jp/company-news/technology/gemini-robotics-ai/

（JST CRDS 人工知能・ロボティクス領域の報告書）

- JST, CRDS-FY2024-FR-03, 研究開発の俯瞰報告書 システム・情報科学技術分野（2024 年）
- JST, CRDS-FY2023-SP-03, CRDS 戦略プロポーザル 次世代 AI モデルの研究開発
- JST, CRDS-FY2023-WR-03, 科学技術未来戦略ワークショップ報告書 次世代 AI モデルの研究開発
- JST, CRDS-FY2021-WR-11, 俯瞰ワークショップ報告書 エージェント技術

- JST, CRDS-FY2019-SP-08, 第 4 世代 AI の研究開発　－深層学習と知識・記号推論の融合－
- JST, CRDS-FY2022-SP-02, リアルワールド・ロボティクス
- JST, CRDS-FY2024-SP-04, 通信と計算の融合による社会のスマート化

（二重過程理論(Dual Process Theory)）

- Yoshua Bengio, NeurIPS 2019, https://www.youtube.com/watch?v=T3sxeTgT4qc
- Daniel Kahneman, Thinking, Fast and Slow (Farrar, Straus and Giroux, 2011). （邦訳：村井章子訳,『ファスト&スロー：あなたの意思はどのように決まるか？』, 早川書房, 2014 年）
- 松尾豊,「知能の 2 階建てアーキテクチャ」,『認知科学』(日本認知科学会誌) 29 巻 1 号 (2022 年), pp. 36-46. https://doi.org/10.11225/cs.2021.062

（世界モデル(World Model)）

- David Ha and Jürgen Schmidhuber, “World Models”, arXiv: 1803.10122 (2018).

３．２．３ 課題の深堀と本質的構造の定義：二層スウォームの統合

本研究対象の図 ３．１．２－１に示す**無人機群運用の自律化**には、**意思決定と制御、論理と物理の階層統合**が不可欠である(図 ３．１．２－２参照)。即ち、課題の本質は、**「物理的スウォーム」と「組織的スウォーム」から成る二層構造をどのように統合するか**という、構造的かつ本質的な技術的挑戦にある(図 ３．１．２－３)。

- **物理的スウォーム**は、陸海空の各種無人機（UAV、UGV、UMV 等）が密集隊形や隊列運動を行う**制御・運動レベルの集団知**である。ここでは、**センサ情報、位置座標、隊形制御則**など、実時間・物理的な要件に基づく制御が主軸となる。
- 一方、**組織的スウォーム**は、各エージェントが人や中央の指示や共有**情報に基づき分散的に意思決定を行い、全体としての目的達成を図る論理的な協調集団**である。ここでは、**状況認識、役割分担、戦術判断など抽象的な意思決定過程**が主軸となる。

これら二層のスウォームは、表 ３．２．３－１に示すように、**動作特性・情報構造・制御様式のすべてにおいて根本的な違い**を有している：

このため、無人機群運用における意思決定と群制御の統合・自律化には、**論理世界（認知・思考）と物理世界（運動・制御）を接続・統一する枠組み「構造整合と抽象化」が必要**となる（図 3.1.1-3 参照）。この接続・統合は、単なる通信インターフェースではなく、**異なる世界モデル、時間軸、機能階層を貫通する統合的 AI アーキテクチャ**を意味する。

本研究では、この構造的ギャップを解消するために、以下のようなアプローチを採用した：

- **OODA ループ理論**を導入し、**観測・認識・意思決定・実行のプロセスを階層的に統合可能な認知構造として整理。**
- 上記の統合を支えるアーキテクチャとして、新知能原理「**絵図・知識・運動系 AI**」に基づく「**RCT-OODA 群制御 AI アーキテクチャ**」を構築。
- 上記アーキテクチャとソフトウェア分散･データモデル中心設計に基づく「制御可能な RCT 世界モデル」と「ソフトウェア分散型 OODA 群制御 AI」を獲得
- **計算力学(CAE)、ゲーム AI 技術**を応用し、**空間・構造の整合性を踏まえた認知思考・行動モデルとして「RCT 世界モデル」**を構築し、論理世界と物理世界の接続を実現。

こうした設計により、**論理構造（組織的スウォーム）と物理構造（物理的スウォーム）の間にある断絶を補完し、未知環境下でも信頼性・柔軟性・最適性を兼ね備えた知的群制御の基盤**を確立することを本研究は目指した。なお、本研究は、論理世界と物理世界の統合が中核的な課題であるため、物理的スウォームの代表無人機を制御対象とした実証を行った。

図 ３．２．３－１　マルチエージェント技術の応用先と技術要求の想定

図　３．２．３－２　無人機群運用におけるスウォームの２層構造

表　３．２．３－１　二層スウォームの特徴

観点	組織的スウォーム	物理的スウォーム
領域	仮想空間（情報・意思決定）	実世界（空間・動力学）
時間スケール	秒～分単位の状況認識・戦術的な意思決定	ミリ秒～秒単位のリアルタイム制御
情報形式	状況評価、目標階層、役割情報	座標、速度、センサデータ
抽象度	高（意味構造に基づく論理情報）	低（物理座標ベース）
制御様式	分散知能、状況駆動、ミッションドリブン制御	フィードバック制御、近接通信

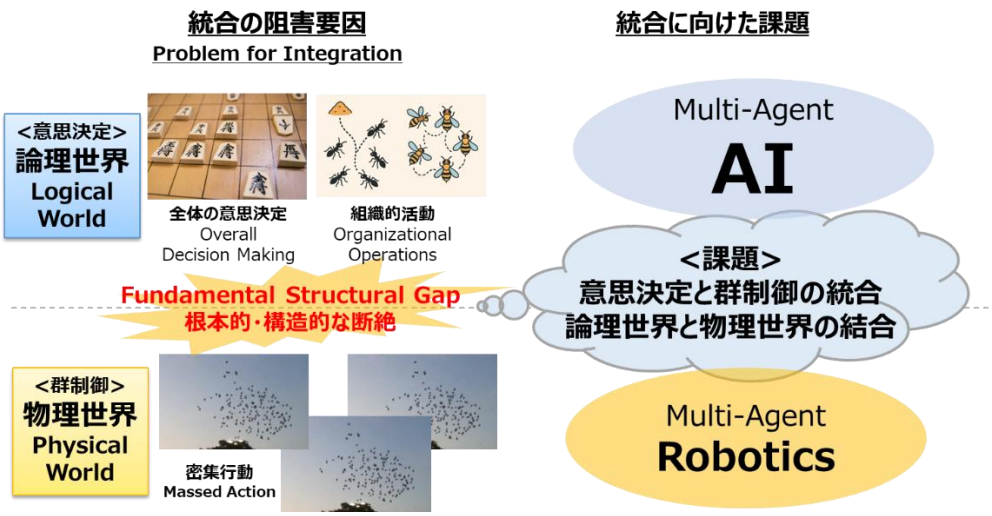

図　３．２．３－３　意思決定と群制御の統合に向けた課題

３．２．４ 無人機マルチエージェント技術体系の構築

（１） 技術体系の概要

本研究では、**知能原理・アーキテクチャ・設計論・要素技術・システム実装・社会実装手法**を一体化した「**マルチエージェント技術体系**」を提案し、防災・警備・物流・交通など多分野への応用展開を見据えた**汎用性・再利用性・進化性のある構造**として整備した。

本技術体系は、分散協調的な任務運用に対応するため、ソフトウェア分散・データモデル中心設計を適用した RCT-OODA 群制御 AI アーキテクチャが中核となる。

即ち、技術体系は、分散協調的なマルチエージェントによる**観測・認識・意思決定・行動**を支える統合技術枠組みであり、原理から運用まで一貫性を持つ点に本質的な特徴がある。

（２） 中核となる 2 つの概念アーキテクチャ

（ア）意思決定・群制御統合「RCT-OODA 群制御 AI アーキテクチャ」

- **知能原理：** 専門家の思考法と OODA 意思決定理論を参考に「状況認識」と「意思決定」の構造を分離し、身体性を付与した「絵図・知識・運動系 AI」知能原理に基づく。
- **技術基盤：** 絵図的知能と CAE（計算力学）技術を融合し、抽象構造の可視化・定量化を実現。二重過程モデルの世界モデルに対して、制御性、透明性を付与し、AI 信頼性を向上。
- **構成：**
  - OODA ループ（Observe-Orient-Decide-Act）の統合制御
  - ソフトウェア分散型 AI モジュール群による自律・協調的判断・行動
  - 制御・可視化可能な RCT 世界モデルによる AI モジュール群の自律協調

（イ）社会実装「MAARC 三位一体」アーキテクチャ

MAARC(Multi-Agent AI, Robotics CPS, and CAE)三位一体 AI アーキテクチャは、RCT-OODA アーキテクチャを社会実装可能するためのプラットフォームとアプローチを構造化したものである(図 ３．１．２-６、図 ３．１．２-７参照)。以下の３つの基盤機能で構成される：

- **① マルチエージェント AI（認知・判断統合）**
  - OODA 群制御 AI＋RCT 世界モデル
  - ソフトウェア分散・データモデル中心設計による協調的知能制御
- **② マルチエージェント Robotics CPS（身体性の実装）**
  - UAV/UGV 等の物理エージェントによるリアルタイム分散制御
  - 通信遅延許容制御、信頼性・安全性・スケーラビリティを実現
- **③ マルチエージェント CAE（任務設計・全体最適化）**
  - 任務モデル・行動計画・最適化を一体化
  - 専門的判断の抽象化・可視化・検証に基づいた AI 設計支援

（３） 社会実装アーキテクチャとしての意義

- **技術と運用を橋渡しする一貫構造**として、設計から現場運用まで接続可能
- **適応性・拡張性・再利用性**に優れ、防災・警備・物流・交通等における**持続可能な省人化・高度化**を実現
- **シミュレーションと実機試験の両立**により、**信頼性・安全性・効率性**を担保した AI 社会実装を支援

このように、本研究では、**理論・設計・実装・運用**を一貫した構造で統合し、**技術整合性と社会応用性を両立**するマルチエージェント技術体系を確立した。

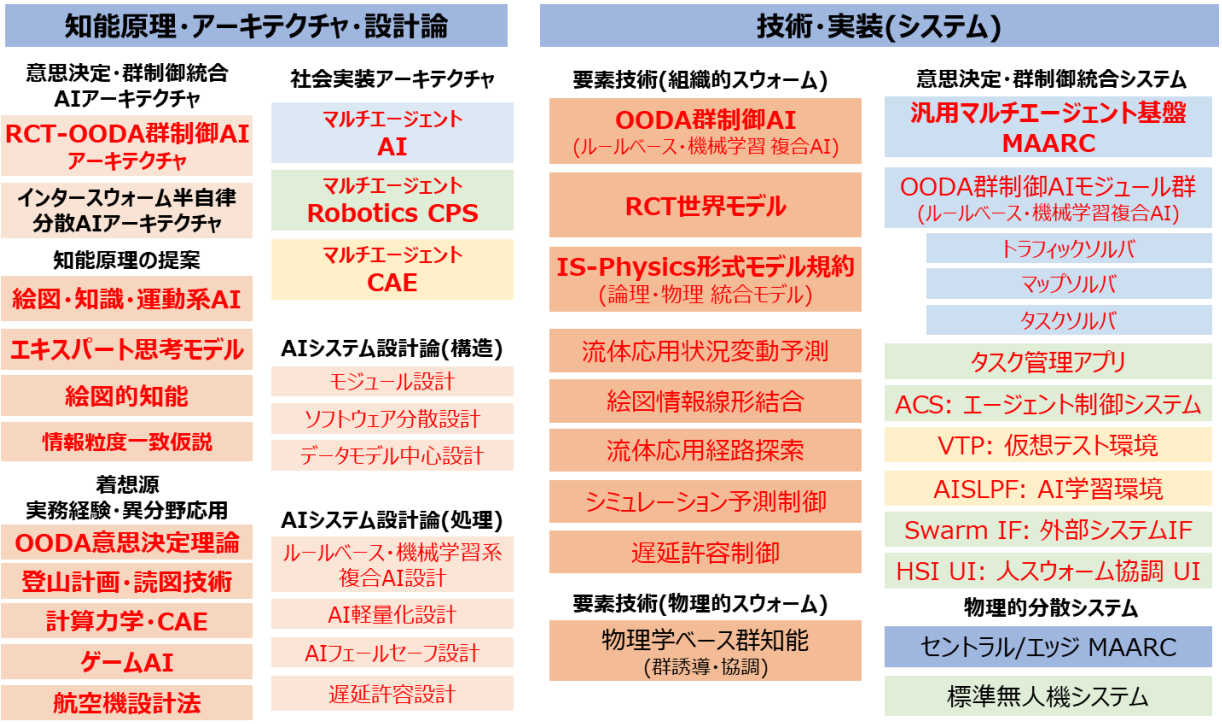

図　３．２．４－１　無人機マルチエージェント技術体系（赤字が本研究の成果）（再掲）

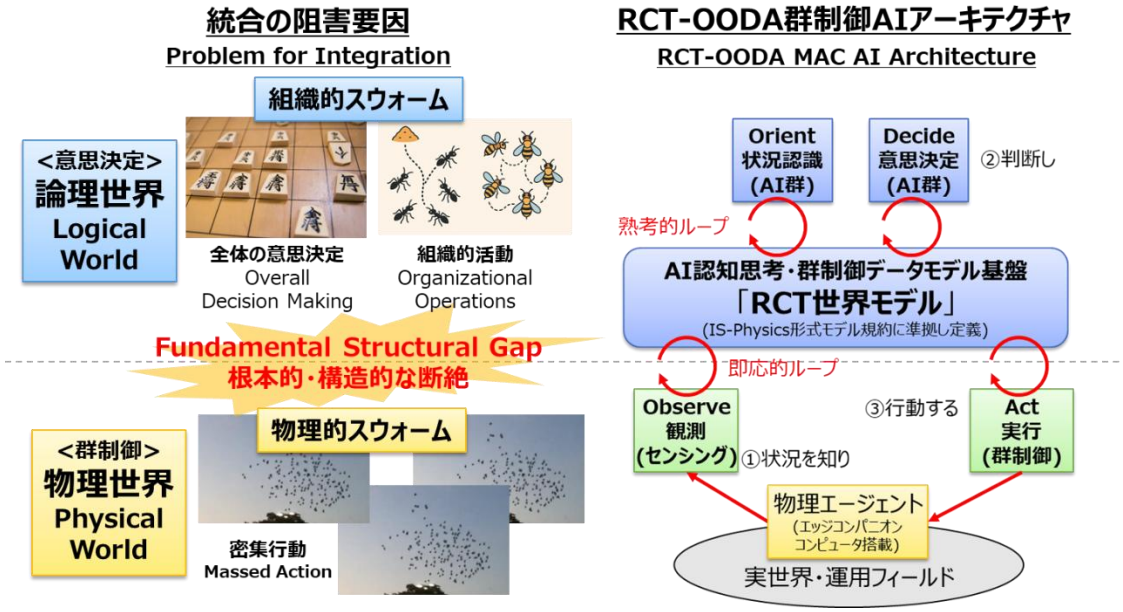

図　３．２．４－２　意思決定・群制御統合「RCT-OODA 群制御 AI アーキテクチャ」概念図（再掲）

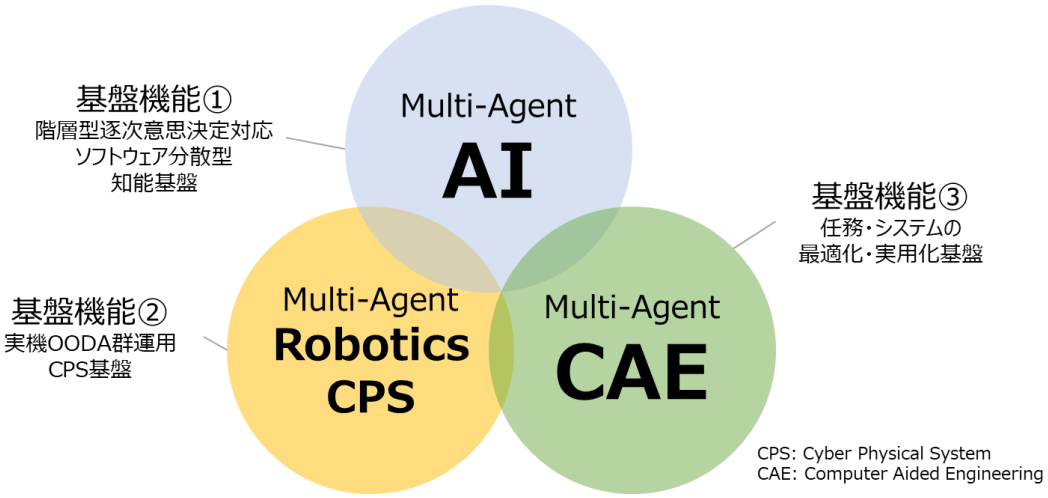

図　３．２．４－３　MAARC 三位一体アーキテクチャの概念図（再掲）

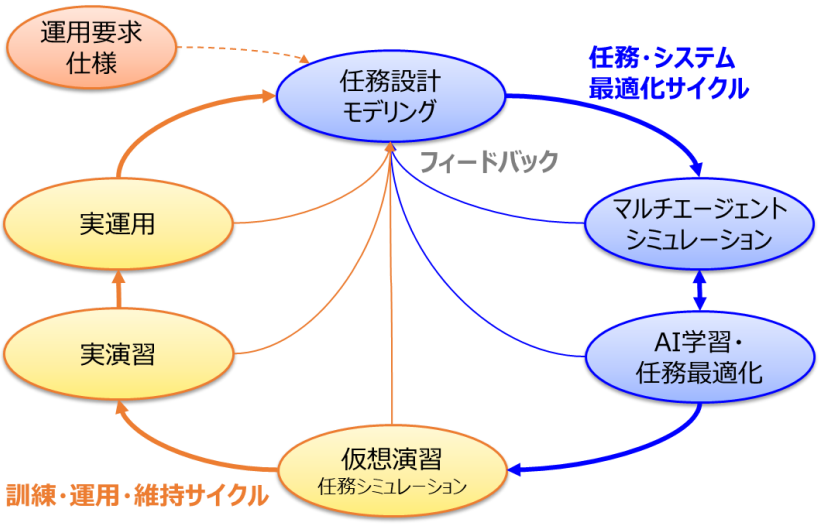

図　３．２．４－４　MAARC 三位一体アーキテクチャによる社会実装モデル（再掲）

３．２．５ 新知能原理「絵図・知識・運動系AI」の提案

本項では、RCT-OODA 群制御 AI アーキテクチャの思想的出発点となった「**絵図的知能**」に基づき、新たな知能原理として「**絵図・知識・運動系 AI**」を提案する。これは、既存の AI 原理を補完・統合しうる新しい枠組みであり、今後の AI 設計における理論的柱として展開することを目指している。

３．２．５．１ 「絵図・知識・運動系AI」の定義

「絵図・知識・運動系 AI」は、**実務経験を持つ専門家の思考様式**(図　３．２．５－１参照)に基づいた AI 設計原理である。特に、図的な構造表現「絵図」を用いて、知識の可視化と空間的把握を可能とする。以下のような特徴を持つ「**絵図的知能**」に着想を得ている：

- 観察対象の**構造や関係性**を絵図として表現
- 絵図を通じて**状況の全体像や変化予測**を把握
- 絵図に基づき**判断と行動計画**を一体的に行う

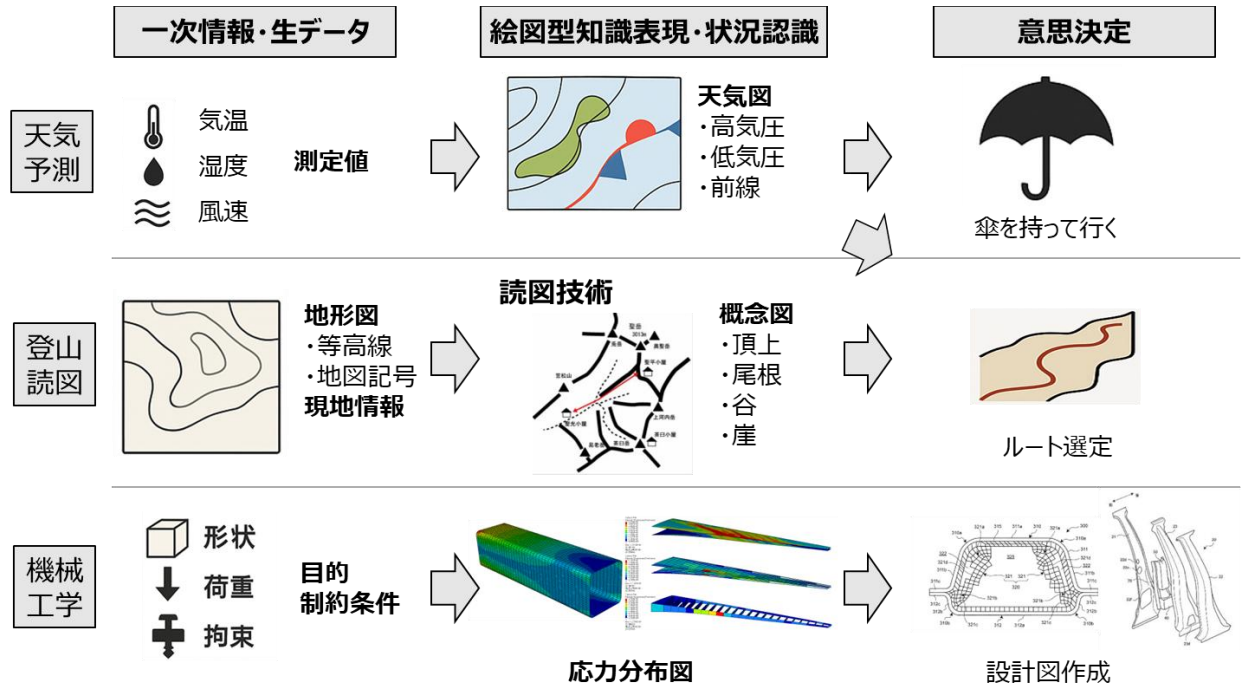

図　３．２．５－１　実務経験に基づく専門家の思考様式・絵図的知能

３．２．５．２ 他のAIとの違いと統合的特性

「絵図・知識・運動系 AI」は、従来の AI が分担してきた知覚・運動処理と知識・言語処理という二つの知能機能を、**絵図という空間的・構造的表現**を用いて統合する新たなアプローチである(表　３．２．５－１、表　３．２．５－２参照)。

従来の**知覚・運動系 AI** は、主にセンサ入力に基づいて物理空間における行動を制御する AI であり、ロボティクスや制御系に適用されてきた。一方で、**自然言語・知識系 AI** は、テキストや論理記述といった記号的表現を用いて、推論や知識処理、対話生成などの機能を担ってきた。これらはそれぞれに特化して発展してきたが、相互の連携には限界があり、**構造理解や行動計画における一貫性の欠如**が課題となっていた。

これに対し、「絵図・知識・運動系 AI」は、**専門家が頭の中で用いている「図的な思考操作」に着目し、知識と運動の間を橋渡しする中間表現**として「絵図」を導入する。絵図は、対象の空間構造や因果関係、行動パターンなどを一望的・直感的に把握する手段であり、**構造理解（どの**

ようになっているか）、状況認識（いまどうなっているか）、行動計画（どうすべきか）を一体として処理できる。

このように本知能原理は、知覚・運動系 AI と知識・言語系 AI の**それぞれの長所を活かしつつ統合**し、現実世界での認知・判断・行動の一貫性と柔軟性を実現するための基盤となる。特に、現場での判断や応用に強い「実践的知能」の獲得に向けた重要な進展であると位置付けられる。

表　３．２．５－１　各知能原理の比較：着想源と課題解決の観点から

知能原理の種類		①知覚･運動系AI	②自然言語･知識系AI	**③絵図･知識･運動系AI**
理論的な基礎		システム１ 即応的ループ	システム２ 熟考的ループ	OODAループ (観測･状況認識･意思決定･行動)
着想源		人間の脳情報処理･ 認知発達過程	人間の脳情報処理･ 認知発達過程	専門家の思考法 絵図的知能
知識表現形式		画像･動画･音声	自然言語	絵図
AIの種類		帰納型･機械学習	帰納型･機械学習	帰納型･演繹型 併用
AI 本質的 課題	資源効率性	× 大量のデータ･計算資源	× 大量のデータ･計算資源	○ ソフトウェア分散設計･RCT世界モデル
	身体性	○ ロボット制御･自動運転	× 原理的にNG	○ RCT-OODA群制御AIアーキテクチャ
	論理性	× タスク分解･論理演算NG	○ 生成AI･対話AI	○ エキスパート思考モデル IS-Physics形式モデル規約
	信頼性	× ブラックボックス性、確率的判断	× ブラックボックス性、確率的判断	○ RCT世界モデルの判断材料可視化
	安全性	× 確率的判断	× 確率的判断	○ AIフェールセーフ設計、AI誤判断検知 ルールベース支援機械学習AI
社会 実装 課題	汎用性	× 専用化している	○ 生成AI･対話AI	○ IS-Physics形式モデル規約 ○ 未知領域はルールベースで先行対応
	進化性･拡張性	× 専用化している	△ 継続的な学習	○ ソフトウェア分散･データモデル中心設計
	相互運用性	× 専用化している	△ 継続的な学習	○ IS-Physics形式モデル規約
①②統合アーキテクチャ		２重過程理論AIモデル		RCT-OODA群制御AIアーキテクチャ

表　３．２．５－２　各知能原理の比較：知識・知能・身体性の観点から

知能原理の種類		**①知覚･運動系**	**②自然言語･知識系**	**③絵図･知識･運動系**
知識	表現形式	視覚 (写真･動画)	自然言語 (用語･文法)	**絵図 (状態図･地図等)**
	専門性	一般的	一般的	**専門的**
	所在	公開･データ多い	公開･データ多い	**偏在･サイロ化**
知能	認知	画像認識AI	大規模言語モデル 対話AI等	**①②の統合 ↓ RCT世界モデル ･ OODA群制御AI**
	思考	囲碁･将棋･戦略ゲーム AI		
身体性	制御	ロボット制御 自動運転等	－	

３．２．５．３ 新原理の必要性：明示的で汎用的な知識表現と知能の身体性

ロボティクス分野では、空間的・物理的な状況を理解し、自律的に行動する「身体性を持った知能」が必要とされる(図　３．２．５－２参照)。従来の AI モデルは、膨大な学習を前提とするため資源効率が悪く、判断根拠も不透明で信頼性が低いという課題がある。

本研究では、「資源効率と信頼性を両立しつつ、身体性を備えた AI アーキテクチャはどのように構築すべきか？」という問題意識に基づき、物理・空間に関する状況認識と意思決定をモデル化し、それを論理的判断と統合するためのアプローチを提案する。

その鍵となるのが、専門家の認知思考構造と知識表現（言語＋絵図）である。これに OODA 意思決定理論を応用することで、明示的で構造的な知識表現と身体性を統合した新アーキテクチャ「RCT-OODA 群制御 AI アーキテクチャ」を提示する。

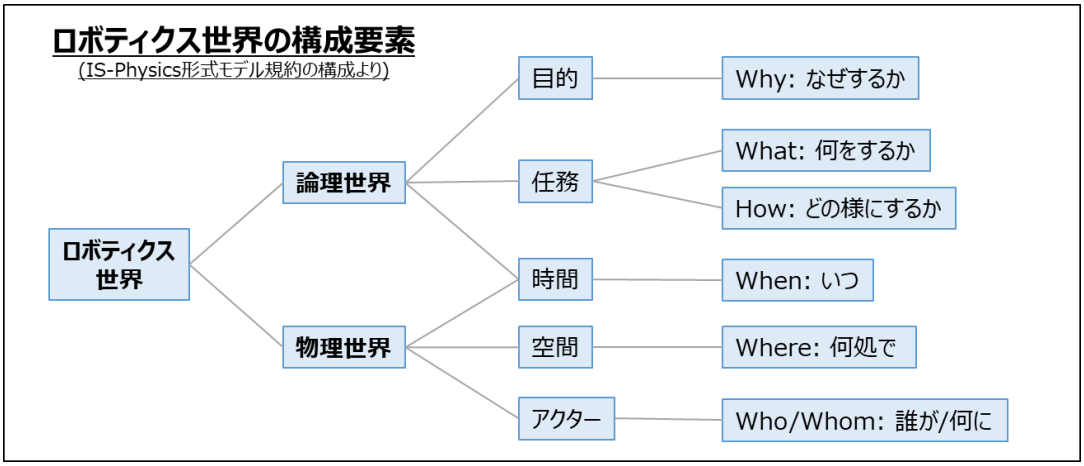

図　３．２．５－２　ロボティクス世界の構成要素

３．２．５．４ 着想の源泉

本 AI アーキテクチャは、筆者が経験した登山での天気予測や読図技術、及び計算力学・CAE による機械設計判断等の思考法に着想を得て、OODA 意思決定理論を踏まえ、体系化したものである（図　３．２．５－３参照）。

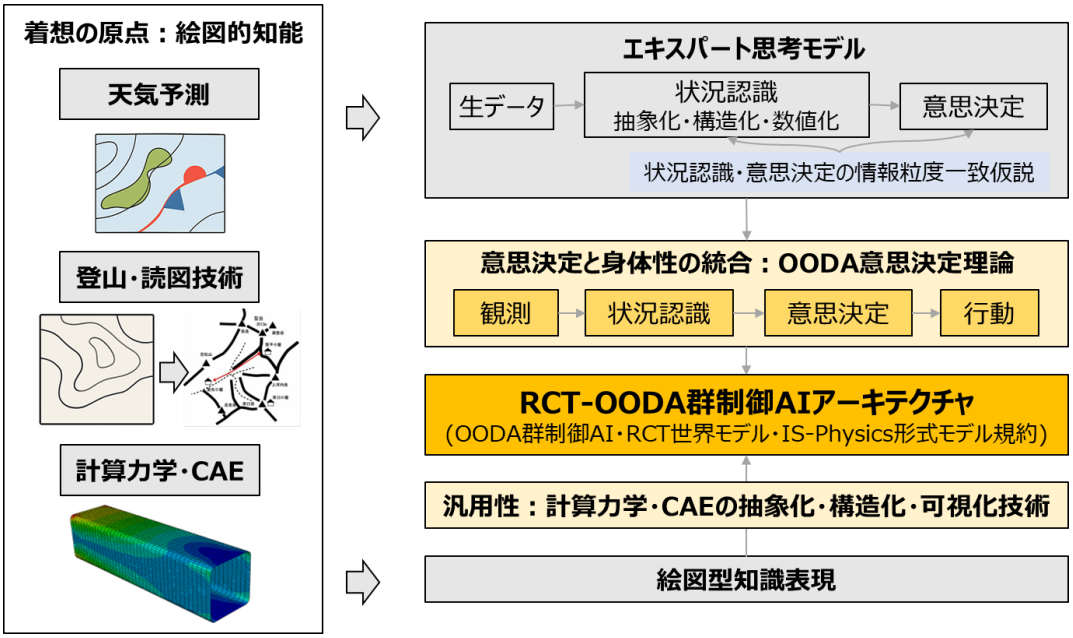

図　３．２．５－３　RCT-OODA 群制御 AI アーキテクチャの着想

３．２．５．５ 専門家の思考法を構造化する「エキスパート思考モデル」

エキスパート思考モデルは、「知識そのもの」ではなく「思考構造」のモデルであり、**直感・判断・行動を統合する認知プロセスの構造化と可視化**を通じて、**高信頼・高説明性 AI** の実現を支える枠組みである(図 ３．２．５－４)。

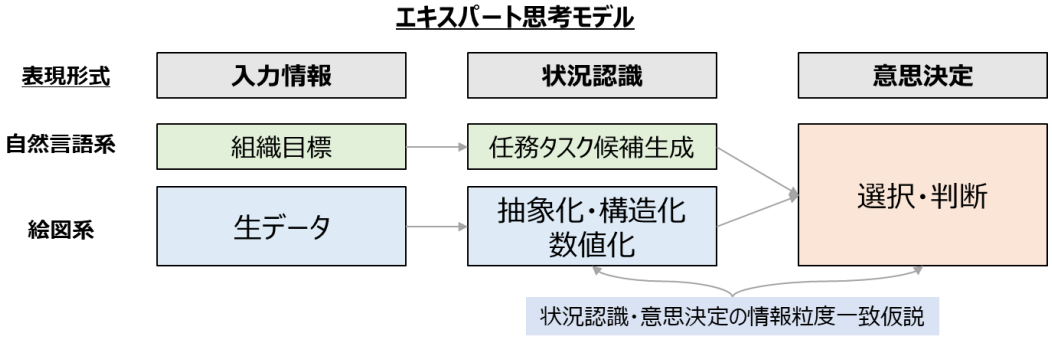

図 ３．２．５－４ エキスパート思考モデルの構成

３．２．５．６ まとめ

●着想：専門家の意思決定に学ぶ AI アーキテクチャ設計

1. 着想の源泉：人間（専門家）の思考様式の構造化
   - 本研究は、人間、特に**専門家の意思決定過程**に着目し、「**状況認識**」と「**意思決定**」を**明確に分離**して捉える。
   - 双方の情報は、**同じ抽象度・情報粒度で整合**している必要があり、この**粒度一致性**が AI の**信頼性の担保**につながる。
   - 特に、状況認識を**可視化可能な構造**として独立させることで、**説明可能性**と**学習効率**を両立する。
2. 現実に学ぶ：天気予報・登山などの応用例
   - 天気図や地形図に代表されるように、**抽象構造に基づいた状況判断と行動選択**は既に実世界で確立された思考様式である。
   - こうした既存の**専門的認知手法**を AI に転写し、**知識の構造化と判断の透明化**を図

●RCT-OODA 群制御 AI アーキテクチャの特徴と利点

- **特徴：独立モジュール型アーキテクチャ**
- 「状況認識」と「意思決定」を**独立して学習・構築できるモジュール構造**を採用。
- 認知モデルと行動モデルを柔軟に組み替え可能な設計。

表 ３．２．５－３ 期待される効果

項目	内容
学習効率の向上	状況認識モデルと意思決定モデルを分離して設計・学習できるため、**学習コストを低減**
信頼性の向上	可視化された状況認識により、**判断根拠が明確**で説明可能な AI が実現
行動の専門性適合	専門知識に基づいた**最適行動選択**が可能

●発展・波及効果

1. 研究面の展望

   信頼性ある機械学習系 AI の構築に向けた 2 段階の研究展開：
   - 人の知識構造をもとにした**可視化可能な陽的モデル**（エキスパート思考モデル）を明示化。

- それを踏まえ、**ブラックボックス的な機械学習世界モデル**との**比較・融合研究**を行い、信頼性の高い学習型世界モデルを確立。

2. **実務面の適用可能性**

モジュール型・汎用型の構造であるため、各分野への適用が容易。
医療、物流、建設、防災、ロボティクスなどの分野で、**専門的マルチエージェントシステムの設計・最適化コストの削減**が期待できる。

３．２．６ マルチエージェントシステム設計論

本項では、無人機群運用における意思決定と群制御の統合・自律化に関するマルチエージェントシステム設計論を示す。本研究の要素技術及びシステムは、本設計論に従い、構築した。

３．２．６．１ 基本構造の設計原理

（１） モジュール設計

システム機能を独立性の高いモジュールに分割することで、保守性・再利用性・構成変更の柔軟性を高める設計方針。エージェントの内部構造や、エージェント間の機能分担にも対応し、構造的な見通しの良さと適応性を確保する。

（２） ソフトウェア分散設計

意思決定や群制御などの知的機能を細分化し､複数のソフトウェアモジュールとして分散配置･連携させる設計手法。物理的な集中型および分散型システムとのハイブリッド構成に柔軟に対応しつつ、冗長性・可用性・スケーラビリティを同時に実現する。

（３） データモデル中心設計

システム全体の整合性･一貫性を確保するために､共通の意味論的データ構造（例：IS-Physics 形式モデル､RCT 世界モデル）を中心に据える設計方式。これにより､モジュールやエージェント間の通信・連携が意味レベルで統一される。

３．２．６．２ AI設計・運用の方針

（１） 複合 AI 設計

明示的なルールベース処理と機械学習による推論を統合する設計手法。状況に応じて処理の切替や協調動作を可能とし、信頼性（可解性）と柔軟性（適応性）を両立。フェイルセイフ設計と連携し、安全性を確保する。

（２） AI 軽量化設計

AI 入力情報に、RCT 世界モデル等を介して意味構造に変換した情報を用いることで、生データの直接入力に比べ、学習コストの低減と推論精度の両立を図る。また、ソフトウェア分散設計により、細分化されたモジュール単位での学習は、その学習コストを大幅に低減できる。

（３） AI フェイルセイフ設計

AI が誤った判断や異常な動作をした際に､安全状態へ自動遷移する機構を備える設計。複合 AI 構成と併用することで、安全性・運用堅牢性を確保する。

３．２．７ 新アーキテクチャの設計・定義

３．２．７．１ OODA群制御AIアーキテクチャ（本研究の初期提案）

OODA 群制御 AI アーキテクチャとは、無人機マルチエージェントを用いて、OODA 理論に基づき、動的な未知環境での意思決定と群制御を自律的に行う AI/IT アーキテクチャである。このアーキテクチャを基にしたシステムは、安全性が求められるため、システム全体の階層構造を考慮し、高い信頼性を保つことが要求される。

本アーキテクチャに基づく運用時の OODA 群制御 AI システムは、図 ３．２．７－１に示す要素で構成される。各構成要素は、表 ３．２．７－１に示す役割を果たす。

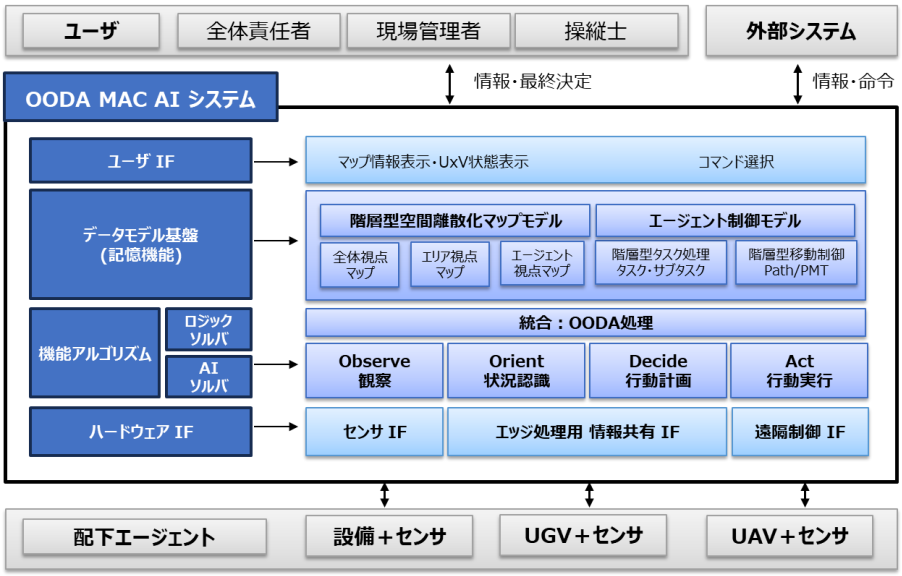

図 ３．２．７－１ OODA 群制御 AI アーキテクチャ

表 ３．２．７－１ OODA 群制御 AI アーキテクチャの構成要素の役割

構成要素	役割
ユーザ	ユーザは、運用責任者・操縦者を想定する。ユーザは、システムの支援を受け状況認識し、配下エージェントの行動を最終決定する。
OODA群制御AIシステム	無人機マルチエージェントを用いて、OODA理論に基づき、動的な未知環境での意思決定と群制御を自律的に行う。通常時はOODAループは自動化されている。異常時はユーザがループに介入できる。観測した生データを分析し、状況や判断材料、行動計画案をユーザに提示する。
配下エージェント	単機または小集団で行動する。センシングした情報と自己状態を上位システムに伝える。

３．２．７．２ RCT-OODA群制御AIアーキテクチャの定義

本項では、「絵図・知識・運動系 AI」設計原理、マルチエージェントシステム設計論に従い構築した新しい AI アーキテクチャと要素技術について概要を示す。これらの要素技術は、汎用マルチエージェント基盤 MAARC に実装した。

RCT-OODA 群制御 AI アーキテクチャ(図 ３．２．７－２参照)は、専門家の思考様式と「絵図的知能」の概念に着想を得て開発された次世代型の AI アーキテクチャである。本アーキテクチャは、意思決定と運動制御を統合する OODA ループ（Observe-Orient-Decide-Act）理論を基盤とし、さらに計算力学（CAE）やゲーム AI 技術を融合することで、汎用性と柔軟性、実装可能性を兼ね備えた構造となっている（図 ３．２．７－３参照）。また、逐次的意思決定と群制御の知的機能を、絵図的な内部モデルと CAE 的構造抽象化を用いて一体的に設計・運用可能とする点において、実

践性・汎用性・拡張性に優れた AI アーキテクチャである。

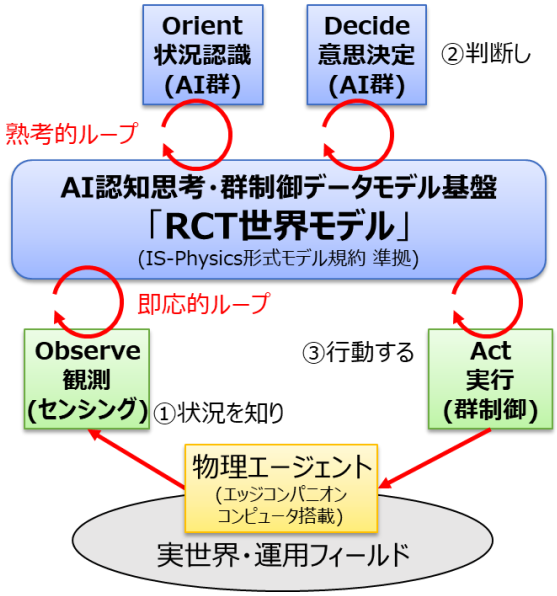

図　３．２．７－２　RCT-OODA 群制御 AI アーキテクチャ

概要：専門家の認知思考様式・絵図型知識表現に、OODA 意思決定理論と CAE の抽象化・可視化手法を応用した AI モデル。RCT は任務構造(Reference, Context, Task) ×評価軸(Risk, Cost, Target)を意味する。出典)安保研究 R5 成果報告書

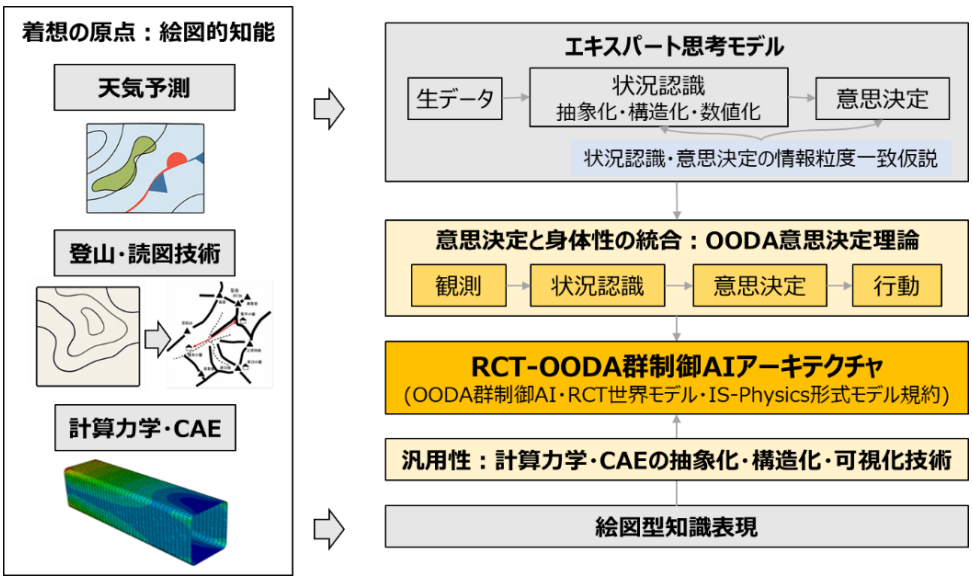

図　３．２．７－３　RCT-OODA 群制御 AI アーキテクチャの着想

３．２．８ OODA群制御AI(意思決定・群制御の統合知能)の構築

定義：OODA 群制御 AI とは、マルチエージェントにおける**意思決定と群制御の自律化・統合化**を担う、**観測・状況認識・意思決定・実行**の各機能を細分化・モジュール化した **AI 機能群**である。本 AI は、**状況分析・タスク生成・目標割当・経路生成・交通管制**などを担う AI モジュールが、**共通基盤である RCT 世界モデル**を介して連携・協調することで、**群全体の目標達成**を実現する。

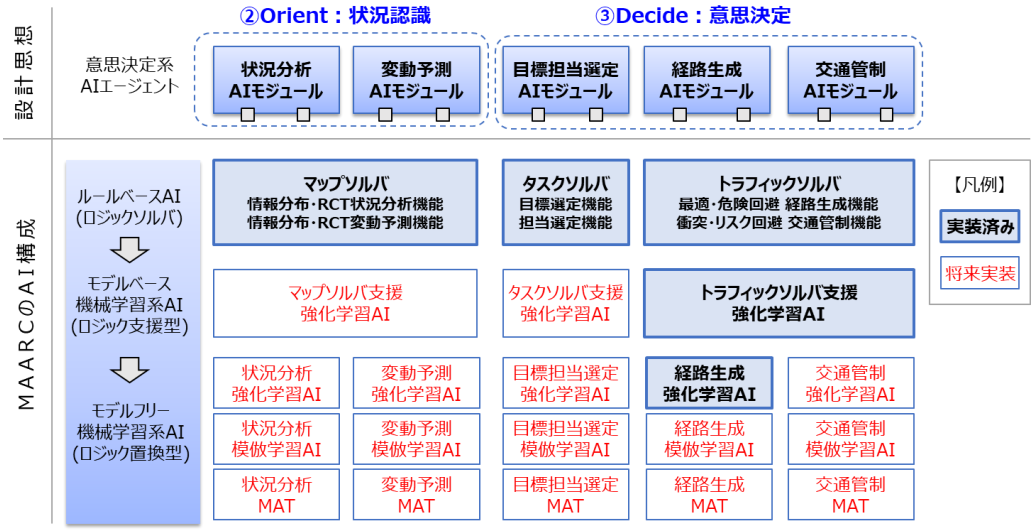

図　３．２．８－１　ソフトウェア分散設計の OODA 群制御 AI のモジュール構成

解説１：OODA 群制御 AI の構造と動作原理

この OODA 群制御 AI は、**AI の知能モジュール化、情報整合、群の自律・協調運用**を同時に実現することで、次世代のマルチエージェント運用基盤に不可欠な中核技術として位置付けられる。

また、以下に基本設計思想と分散設計思想と分散化設計方針を示す。

基本設計思想：

- 各エージェントが **自律的に OODA ループ（Observe-Orient-Decide-Act）** を実行
- 各機能は**ソフトウェア分散・データモデル中心設計**に基づき、**モジュール化**
- **RCT 世界モデル**を共通の情報基盤として参照・更新することで、組織的な整合判断を実現

分散設計方針(協調行動と通信設計)：

- 各エージェントは、必要最小限の**状況・意図情報を共有**
- 通信量を抑えつつ、**協調行動の整合性を確保**

表　３．２．８－１　OODA のプロセスと情報の流れ

フェーズ	内容
観測（Ob）	センサ等から環境情報を取得（生データ）
状況認識（Or）	生データを抽象化・構造化し、RCT マップの**状況図**として表現
意思決定（D）	局所 RCT 情報に基づき、任務目標と状況を踏まえた**最適行動方針を選択**
行動（A）	選択した行動方針に基づいて**実行動作を開始・制御**

表　３．２．８－２　OODA 群制御 AI の特徴

観点	特徴・利点
知能の構造化	各 OODA 機能を**明示的にモジュール化**し、再利用・適応が容易
認知の共有基盤	**RCT 世界モデルを介した認知と判断の整合性**により、粒度一致と情報透明性を確保
自律と協調の両立	各エージェントが自律的に判断しつつ、必要に応じて協調行動を実現（**スケーラブルな群制御**）
運用柔軟性	集中・分散の**ハイブリッド運用に対応**し、状況に応じた最適な制御形態を選択可能

表　３．２．８－３　拡張性と実績・計画

項目	内容	実績・計画
集中モード	現行設計では、中央ノードによる支援のもとでの運用（状況統合・判断支援）を基本とする	安保研究 R5 で試作・検証 安保研究 R7 で AI を高度化
分散モード	今後は、**通信制約下でも自律運用可能な完全分散型モード**への拡張を進行中	安保研究 R7 で実施
エッジ実装	UAV・UGV などの物理プラットフォームに向け、**エッジデバイスで動作する軽量モジュール**の実装を計画中	安保研究 R7 で実施
最終目標	**実環境における高信頼・高効率な群制御**と、**スケーラブルな協調 AI 基盤**の確立	安保研究 R7 で実施

３．２．９ RCT世界モデル(AI認知思考制御基盤)の構築

定義：

RCT 世界モデルとは、実世界の情報を**抽象化・構造化・数値化**し、AI および人による**状況認識・意思決定・群制御**を統合的に支える**認知・情報共有基盤**である。本モデルは、**IS-Physics モデル規約**に準拠し、抽象化粒度や構造化様式を**人が設計・調整可能**とする。

ここで「RCT」は以下の 2 つの参照・評価軸を表す：

- **参照軸**：Reference（基準）、Context（状況）、Task（課題）
- **評価軸**：Risk（リスク）、Cost（コスト）、Target（目標）

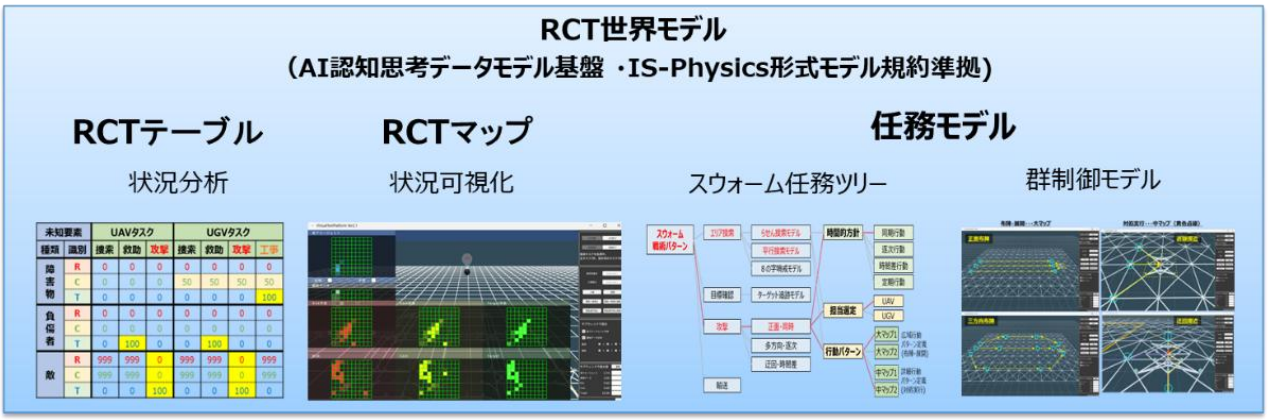

図　３．２．９－１　RCT 世界モデルの基本構成

３．２．１０ IS-Physicsモデル規約：意思決定と群制御の統合モデル記述規約

３．２．１０．１ モデル記述規約の定義と設計思想

定義：

IS-Physics モデル規約とは、**AI の状況認識・意思決定において必要な情報粒度と構造化様式**を、**CAE（Computer-Aided Engineering）技術に基づいて調整・設計可能とする記述規約**である。本規約は、現象の空間的・構造的理解を前提とする**計算力学的な抽象モデル**の構築に適しており、AI の判断基盤となる**世界モデルや意思決定支援システムの共通記述仕様**として機能する。なお、IS は、InterSwarm の略である。

解説：

このモデル規約は、**AI と CAE 技術の融合**を促進する技術的インターフェースであり、専門家知能の構造的モデリングを可能とする、次世代 AI システム設計の要となる。計算力学・CAE 技術を応用し、あらゆるユースケースに対応できる高い汎用性を有するマルチエージェント用モデリング規約である。

表　３．２．１０－１　IS-Physics 形式モデル規約の特徴

観点	内容
粒度調整性	状況や任務に応じて、**情報の詳細度（粒度）を動的に調整**可能
抽象構造表現	等高線・メッシュ・フローライン等の **CAE 的な空間表現方式**を、AI 判断基盤のモデル記述に応用
応用範囲	RCT 世界モデルや OODA 群制御 AI における**状況認識・判断根拠の構造化と共有**に活用
利点	情報の構造整合・再利用性・判断透明性を高める記述ルールとして、**分散 AI の一貫性ある認知基盤**を実現

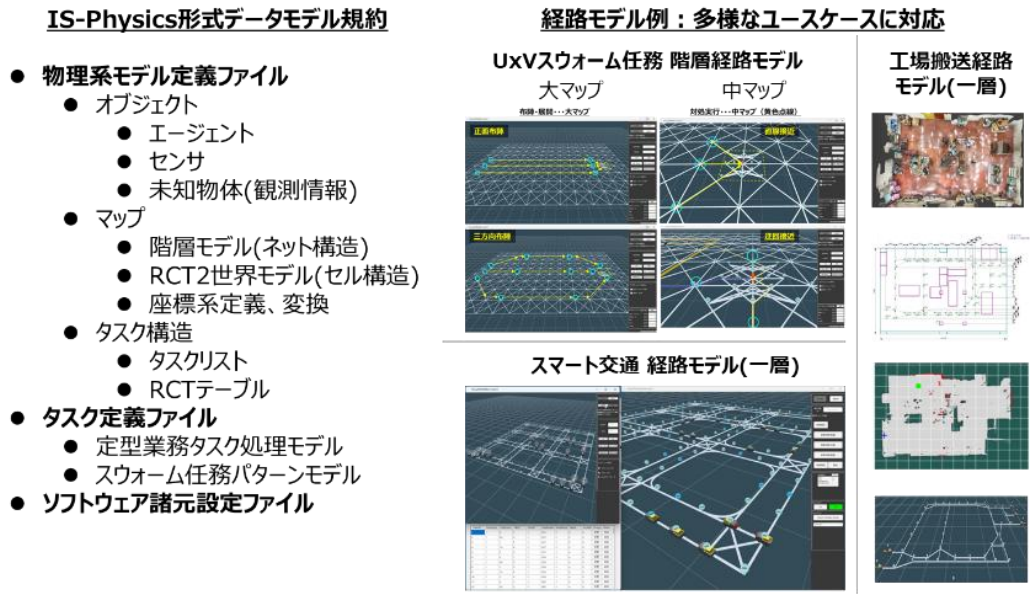

図　３．２．１０－１　IS-Physics 形式モデル規約の特徴

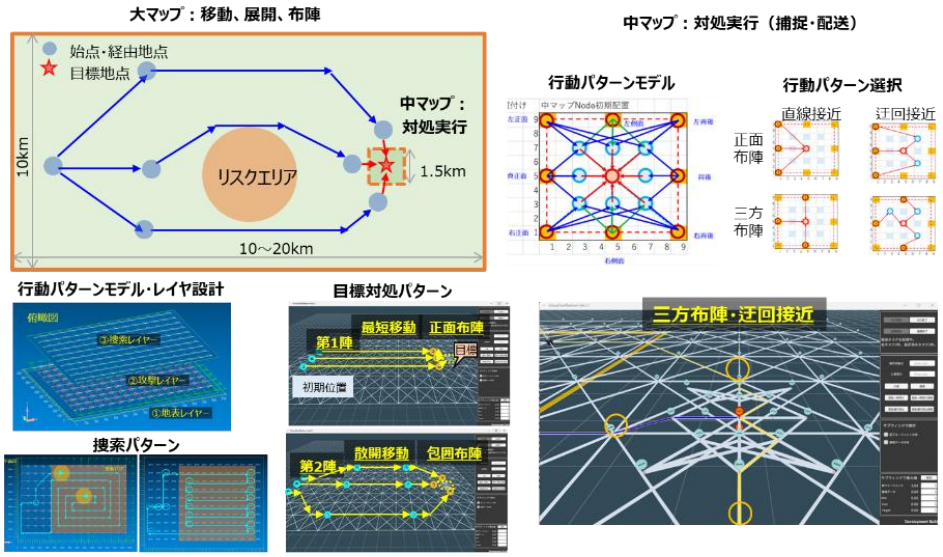

図　３．２．１０-２　スウォーム任務モデル(階層経路モデル)の例

３．２．１０．２ 意思決定と群制御のための構造化モデリング方針

本項では、IS-Physics モデル規約における構造化モデリングの基本方針を示す。特に、**未知環境下の逐次意思決定と群制御に関わるマルチエージェント問題を、抽象化されたデータ構造としてどう記述しうるか**を焦点とする。

（１）対象：マルチエージェント意思決定の構造と記述要件

未知環境における逐次意思決定問題（例：競合型不完全情報ゲーム）は、以下のような**複合構造を持つマルチエージェント問題**である：

- チーム全体の行動計画と、各エッジエージェントの個別行動が**相互に作用**し、さらに敵対勢力の行動も加わることで**マルコフ決定過程の多重性**を持つ
- 各エージェントの意思決定は、**職位や役割に応じた視点で行われるため、階層構造を伴う**

このような問題において必要とされるモデル化とは、単に**任務環境の仮想空間再現**にとどまらず、以下の構造的要件を備える必要がある：

- **AI の認知過程（知覚・推論・判断）**を支える情報構造の記述
- 判断材料の**抽象・捨象・分類・予測・整理**のプロセスを記述可能とするモデル構造
- 上位指揮者からの命令（オーダー）も含めた一連の意思決定サイクルを構造的に記述可能とすること

さらに、これらのモデルを効率的に扱うためには、以下の要件が求められる。

- モデル間の整合性を確保した**体系化・構造整理**
- 異なる問題に対応可能な**モデル記述の自由度と標準化の両立**

IS-Physics モデル規約は、このような要件に応えるための、**AI 研究における「文法」としての共通記述仕様**である。

（２）HSI-IF 対応：体系化・定型化による制御負荷の軽減

本モデル規約のもう一つの柱は、**HSI（Human-Swarm Interaction）への適応性**である。モデルを体系化・定型化することにより、**人間の操作者による理解・操作性を向上**させ、**制御負荷の低減**を実現する。

特に以下のような応用を想定している：

- **エッジエージェント（移動体）は、中央 AI からのタスク指示に基づいて行動**

- 行動は、**タスクライブラリから選択されたアクション**として実行
- タスクライブラリは、**搬送・防災・防衛任務など多様なユースケース**に対応可能
- 各タスクは、**複数の基本行動（行動要素モデル）**の組合せにより構成され、**複雑な行動もモジュール的に記述・拡張可能**

この定型化は、**GUI やアイコンベースのインターフェースとの親和性も高く**、直感的な HSI 設計の基盤ともなりうる。

３．２．１０．３ モデル規約体系および実装基準（構成・座標系）

本項では、IS-Physics 形式モデルの根幹を成す**モデル記述規約体系**と、その**実装基準（特に座標系仕様）について述べる。これらは、マルチエージェント AI が現実世界と論理モデルの整合性を維持しながら、自律的な認知・意思決定・行動を行うための共通インターフェース**である。

（１） モデル規約の構成とデータモデル体系

IS-Physics 形式モデルは、**マルチエージェント認知・行動モデルの記述に関する共通ルール（モデル記述規約）**であり、**自然言語における文法に相当する役割**を担う。
本規約は、**CAE（計算力学）技術を基盤としたデータ構造の階層体系**に従っており、以下のような構成要素を持つ（図 ３．２．１０−３ 参照）：

- **節点（Node）**
  空間上の基準点。すべての構造の基礎座標を定義。
- **ライン要素（Line）**
  節点間を結び、経路・ネットワーク・行動軌跡を表現。
- **セル要素（Cell）**
  節点群で囲まれる領域を構成し、空間の面積的・体積的区画を定義。
- **マップブロック（MB）**
  Cell・Line 構造を組み合わせた、意思決定・群制御のための構造的仮想空間。

このように、**Node-Line-Cell-MB** に基づくモデル構成により、マルチエージェントの**移動制御・認知・行動計画**に必要な情報の空間整合性と構造一貫性が確保される。

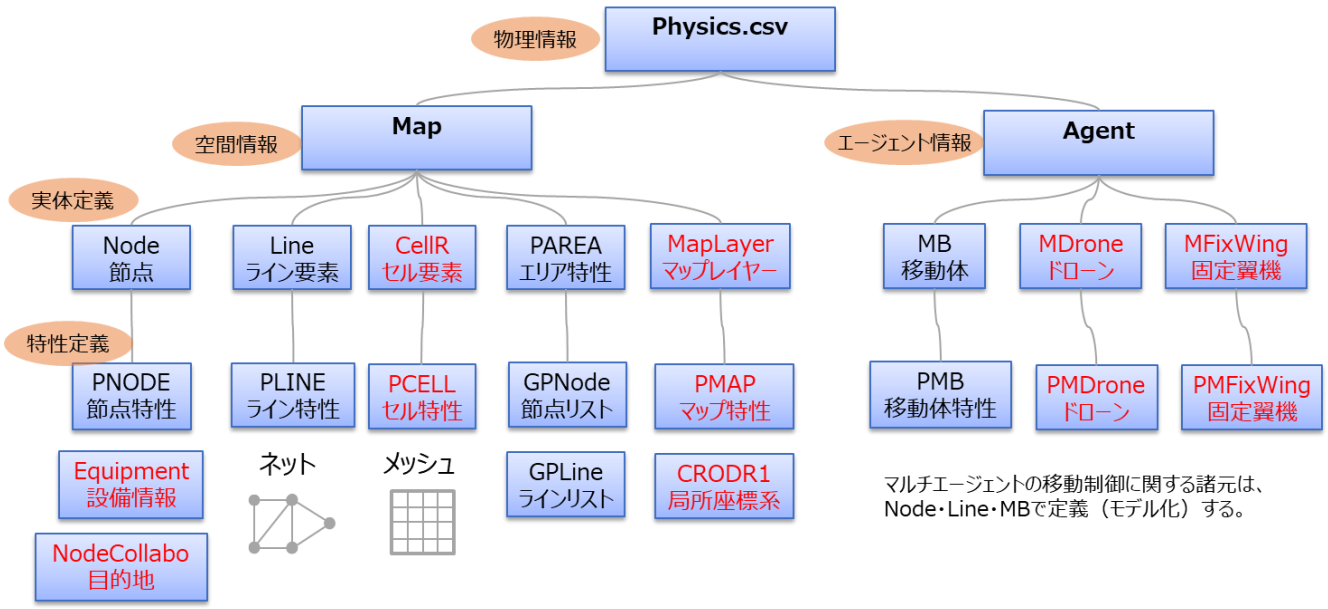

図 ３．２．１０−３ モデル規約：IS-Physics 形式 物理系データモデル体系

（２）実装基準としての座標系仕様

IS-Physics モデルの**実装環境間での整合性を保つために、空間記述に用いる座標系の取り扱い規約を明確化**する必要がある。

本研究で構築された OODA 群制御 AI システムでは、**右手系（right-handed coordinate system）を標準基準**として採用している。これは、機械工学や航空工学をはじめとする多くの物理システムにおいて標準的に用いられている座標系である。

一方、各構成システムや開発プラットフォーム（例：Unity 等）は、独自の座標系（例：左手系）を採用している場合もある。よって、以下のような実装基準を定めている（表 ３．２．１０－２、図 ３．２．１０－４参照）：

- **内部処理では、各開発環境に応じた座標系の使用を許容**
- **ただし、UI 表示、IF（インターフェース）出力、外部連携においては、右手系で統一**

このように、**環境依存性を吸収しつつ、共通認識を保つための座標基準の設計**は、**異種エージェント間の連携やシステム統合において不可欠な実装ルール**である。

表 ３．２．１０－２　OODA 群制御 AI システムの座標系の取扱い

項目	内部	UI 表示/IF 出力	備考
IS-Physics 形式モデル	右手系	右手系	
LG ソルバ	右手系	右手系	
ACS	左手系 *1	右手系	*1 Unity に依存
VTP Plant	左手系 *1	右手系	*1 Unity に依存
無人機システム	(業界依存)*2	右手系	*2

注記）*1 Unity の座標系は、左手系、地面が zx 平面、上方向が y+方向が標準となっている。*2 無人機システムの座標系は産業や学術の領域に応じて異なる。

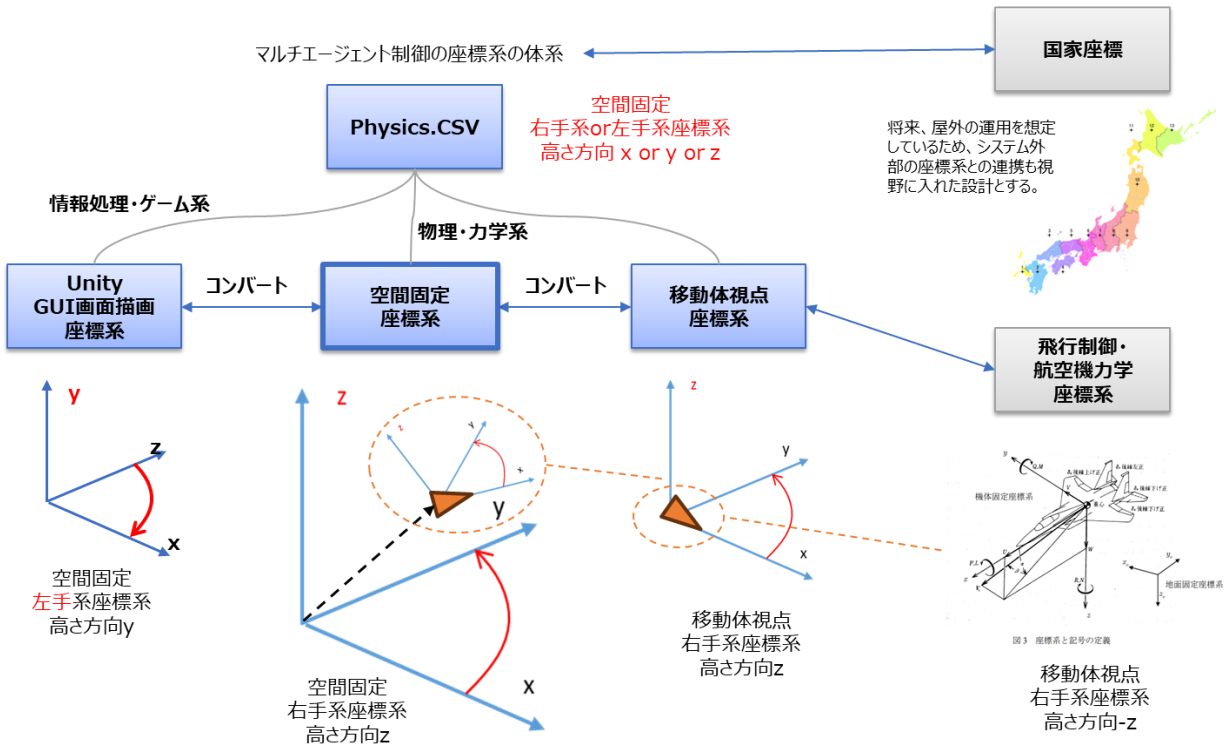

図 ３．２．１０－４　座標系の種類

３．２．１０．４ マルチエージェント構成要素に応じたモデル種別

本項では、IS-Physics 形式モデルが対象とする**マルチエージェントシステムの構成要素に応じたモデル種別**を整理する。これらのモデル群は、**空間情報の構造化・行動モデルの汎用化・認知支援・学習最適化**など、複合機能に対応するための中核的な設計要素である。

（１） ソフトウェア分散・データモデル中心設計の意思決定モデル

OODA ループによる意思決定と群制御を実現するためには、**空間情報マップと OODA 意思決定アルゴリズムとの連携**が不可欠である。IS-Physics モデルでは、これを**ソフトウェア分散構造とデータモデル中心設計**により実装している。

（２） 空間情報マップモデル

マルチエージェントシミュレーションAIやゲームAIの研究においては、運用フィールドや仮想環境のモデリングに多様な形式の**空間情報マップモデル**が使用されている。研究開発および社会実装の現場においては、次の2種類の構造が広く用いられている。

- **グリッド型マップ（セル構造）**
  空間を碁盤目状の格子（セル）に細分化し、エージェント（プレイヤーや移動体など）は、この格子上を一定のルールに従って遷移・移動する。典型例として、戦略シミュレーション、探索AI、経路計画タスクなどがある。
- **ネット型マップ（リンク構造）**
  実際の道路網や経路構造を、ノード（交点）とエッジ（接続路）のリンク構造としてモデル化する。現実の形状を忠実に再現した構造や、トポロジ的に同一の抽象構造などが含まれる。交通管制・航空路管制・鉄道管制などでの社会実装実績がある。

IS-Physics形式モデルは、これらのマップ構造の表現に柔軟に対応可能であり、以下の要件に基づきモデル設計が行われている：

- **未知環境における不完全情報ゲーム**に対応するため、
  - 我方中央エージェントと配下エッジエージェントの視点による**認知空間モデル**、
  - 敵対勢力の中央およびエッジエージェントの視点による**敵対認知空間モデル**、
  - 両者の行動を監視・判定する**審判視点モデル**の3つを、**統一的に記述可能なモデル構造**を備える。
-
- モデル構造は、これまでの**マルチエージェントAIやゲームAI研究で蓄積された知見・アルゴリズム・実装資産の再利用**を可能とするよう設計されている。

IS-Physicsモデルにおける空間マップは、AIの認知・判断・行動支援の基盤となる情報分布を記述するためのものであり、意思決定者の視点に応じて適切なマップ構造（グリッド型・ネット型・階層型など）を柔軟に適用できる。

なお、現時点ではこれらのマップモデルは事前に静的に生成する設計となっているが、今後は**状況予測や動的環境変化に基づいて、マップ構造をリアルタイムに動的生成できるモデル基盤**への拡張を計画している。

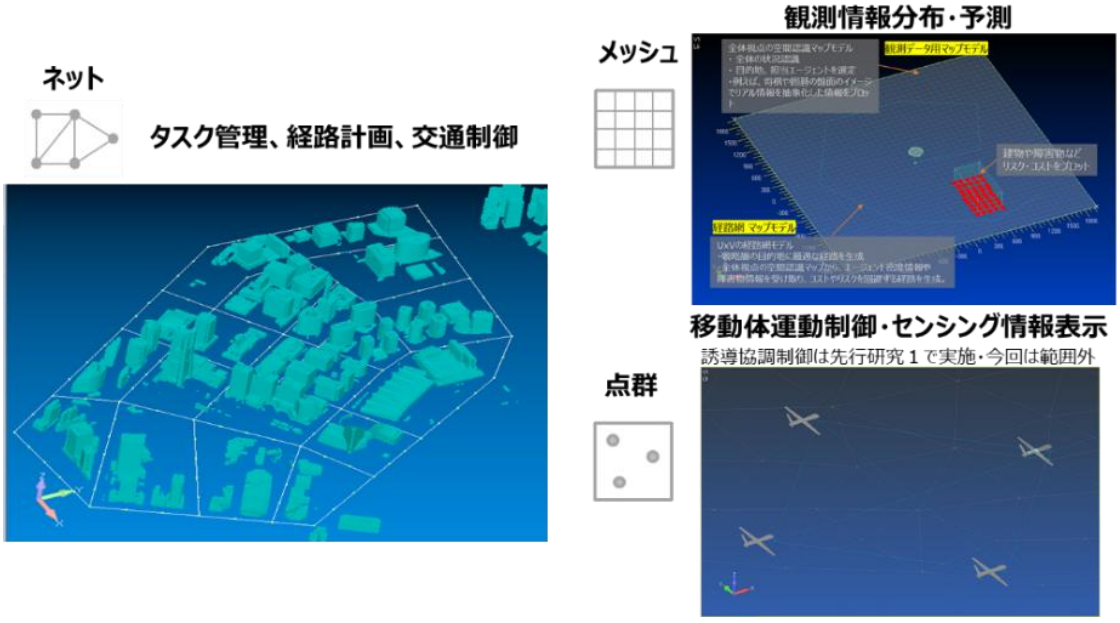

図　３．２．１０－５　AI 認知思考・群制御用　空間情報マップモデルの種類

意思決定の視点に応じて適切なマップ構造を適用できる。各マップは事前にモデリングし、各ソフトウェアが仮想空間上にマップを生成する。将来はダイナミックに生成できるようにする。

（３）　マップレイヤーモデル

未知環境・不完全情報ゲームに対応するため、図　３．２．１０－６に示すようなOODAループの各機能に適したマップ構造とマップレイヤーを双方とも備える必要がある。

配下エッジエージェントがセンシングした相手情報の生データは点群マップに保存され、OODA各機能に応じたマップに抽象化プロットされる。但し、観測していない相手は見えない。中央は、各マップに基づいて状況認識や行動決定を行う。

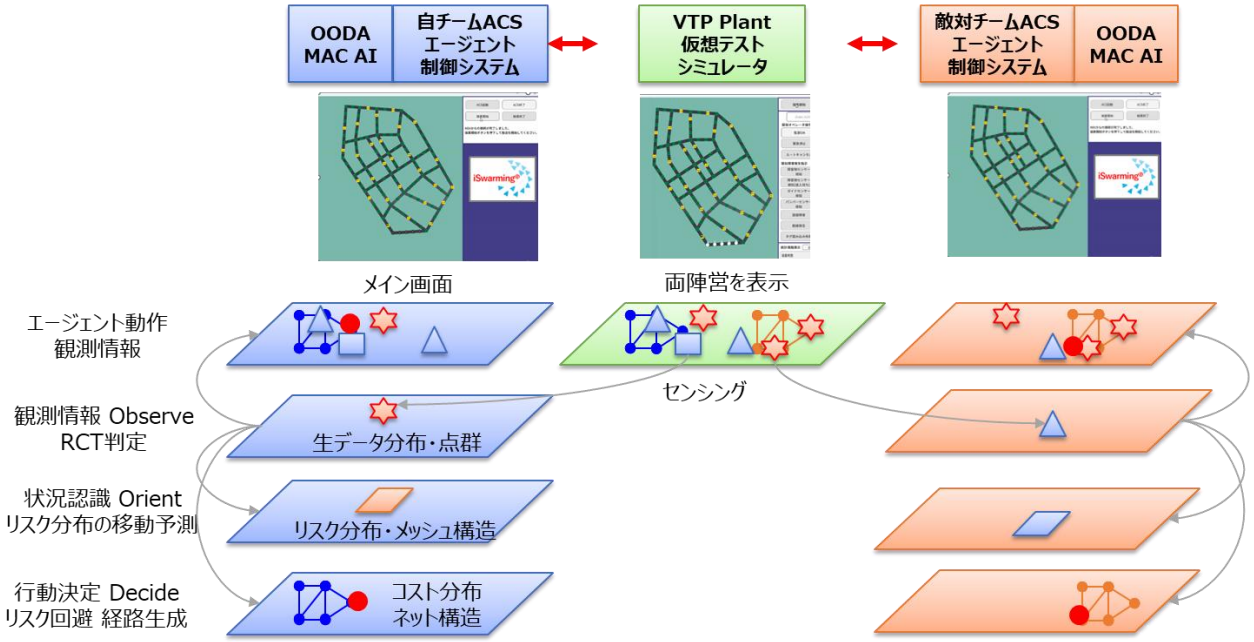

図　３．２．１０－６　OODA 対応　IS-Physics 形式マップレイヤーモデル利用イメージ

（４）　エッジエージェント行動モデル

中央のタスク指示に基づいて、配下エッジエージェントが行動できるようにタスクライブラ

リを備える(図　３．２．１０−７参照)。移動体（エッジエージェント）は、上位の中央のタスク指示に従い、アクションをタスクライブラリから選択する。搬送任務、防災任務、指揮統制任務に応じて、モデルを拡張できるようにする。ここでライブラリとは、機能を実現するプログラムの部品である。このライブラリの振る舞いは、設定ファイルで調整できる。

図　３．２．１０−７　エッジエージェント行動モデル：移動体モデル＋タスクライブラリ

（５）　タスクモデル

各タスクは、基本行動モデルで構成される。タスクの種類が増えても拡張性が保てる構造とする(図　３．２．１０−８参照)。また、タスクモデルは拡張容易な構造とし、タスクに応じたエッジエージェントの機能も拡張容易な構造とすること。移動体（エッジエージェント）は、上位の中央のタスク指示に従い、アクションをタスクライブラリから選択する。タスク型モデルは、搬送任務、防災任務、防衛任務に応じて、モデルを拡張できるようにする。各タスクモデルは、行動要素モデルの組合せで構成される。複雑な行動も、複数の基本行動に細分化できる。

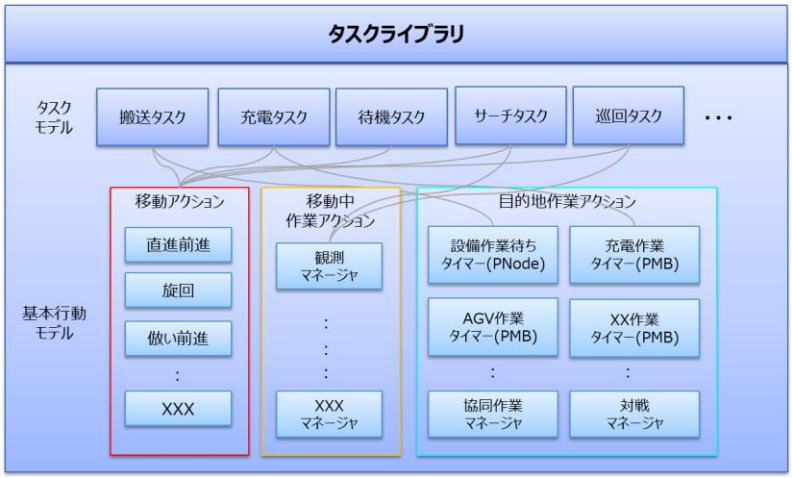

図　３．２．１０−８　エージェント制御モデルの構成

（６）　最適化モデル

AI学習を容易に実行可能とするため状態s、報酬r、及び行動aに必要なデータへのアクセスを容易に実行できるデータ構造とすること。計算力学の分野の最適化条件とAI分野の強化学習条件は、最適化と強化学習は考え方の類似性が極めて高い。従来の最適化はファイルレベルの相互作用で目的関数を最大化する。強化学習は、ファイルレベル及び内部変数レベルでの相互作業で報酬を最大化する。よって、最適化モデルは、従来の最適化をベースに強化学習対応に拡張する。

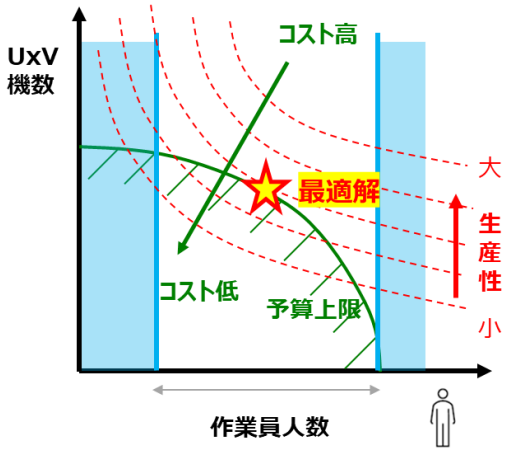

強化学習条件：

報酬r ＝ 目的関数
状態s ＝ 解析結果
行動a ＝ 設計変数

最適化条件：

制約条件：予算上限

目的関数：生産性 最大化

解析結果：　生産性指標
トラフィックデータ

設計変数：作業員数
UxV機種･数
経路計画ロジック

設計変数制限：作業員数の上限･下限

図　３．２．１０－９　最適化条件・強化学習条件の最適化モデル

３．２．１０．５ 研究応用とマップ構造への展開

本システムは、必要な要素技術の基礎研究を支援するための研究支援プラットフォームとして、先進技術基盤を育成するためにも活用可能なものとするため、多様なマルチエージェント研究に用いられているマップ構造への対応が求められる。

（１）　調査検討

マルチエージェント研究において、研究者の研究課題に応じて、様々な構造のマップが使用されている。大きく分けると2種類ある。

一つ目は、ネット型のマップ構造である。これは、図　３．２．１０－１０に示すように、実際の経路をノードとエッジのリンク構造でモデル化したものである。現実に忠実に再現したものや、トポロジのレベルで同一となるように抽象化したものなどがある。社会実装されているものとしては、交通管制や航空管制、鉄道管制などの領域で使用されている。

二つ目は、グリッド型のマップ構造である。これは、図　３．２．１０－１１～図　３．２．１０－１２に示すように、空間を碁盤目状の格子「グリッド（セル）」に細分化・分割したものである。エッジエージェント（プレイヤー・駒・碁石など）は、グリッドを一定のルールで移動する。

（２）　機能要求

AI SLPF は、マルチエージェント研究において使用されているグリッド型(セル型・ボクセル型を含む)のマップ構造、及びリンク型のマップ構造に、同一のモデリング規約で対応できることが求められる。

本システムは、図　３．２．１０－１３～図　３．２．１０－１６に示すように、リンク型のマップとグリッド型のマップのどちらにも対応可能である。

図　３．２．１０−１０　ネット型マップによる MAS AI 研究・社会実装の例

不完全情報ゲームの一種である警備ゲームのモデルは、宝崎隆祐 2016，ネットワークを考慮した警備ゲームのモデルあれこれ，オペレーションズ・リサーチ https://orsj.org/wp-content/corsj/or61-4/or61_4_226.pdf、及び富士通岩下氏他の研究論文「都市の警備配置問題を高速に解く AI 数理技術」から引用した。また、道路交通や航空管制において、ネット構造マップによる情報提供、管制制御を行っている。

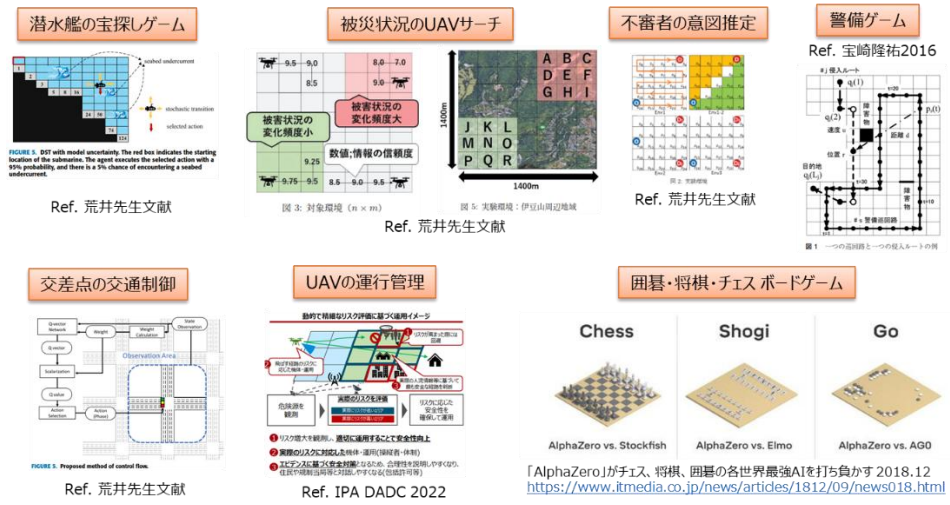

図　３．２．１０−１１　ネット型マップ構造による MAS AI 研究・社会実装の例

マルチエージェントシミュレーション AI 研究のモデルは、資料「調査まとめ_荒井先生マルチエージェント研究_231219.pptx」から千葉大学荒井先生の文献から引用した。不完全情報ゲームの一種である警備ゲームのモデルは、宝崎隆祐 2016，ネットワークを考慮した警備ゲームのモデルあれこれ，オペレーションズ・リサーチ https://orsj.org/wp-content/corsj/or61-4/or61_4_226.pdf から引用した。また、実機を前提とした UAV の運行管理の例は、IPA DADC「自律移動ロボットアーキテクチャ設計報告書」、資料「調査まとめ_CDRS 俯瞰報告書マルチエージェント技術_231219.pptx」から引用した。また、囲碁・将棋・チェスもグリッド構造マップのゲームである。

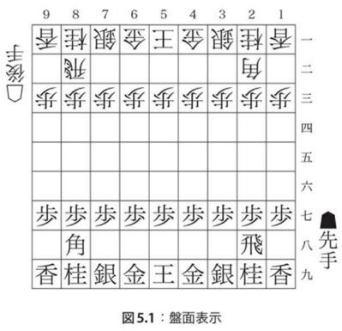

図5.1：盤面表示

図5.2：cshogiの座標系

図　３．２．１０−１２　グリッド型マップの２次元 ID 付番例

文献「山岡忠夫 2021，強い将棋ソフトの作り方 Python で実装するディープラーニング将棋 AI，マイナビ出版」から抜粋。グリッド型マップの代表例として示す。グリッド型マップの位置の表現方法は、２次元 ID 方式である。将棋では、位置特定をアルファベットと数字の２次元 ID で表現している。囲碁やチェスも同様である。他のマルチエージェント研究のグリッド型マップも２次元 ID 方式を採用している。２次元 ID 方式では、地理的な要素を含むマルチエージェント問題には使いにくいという問題がある。

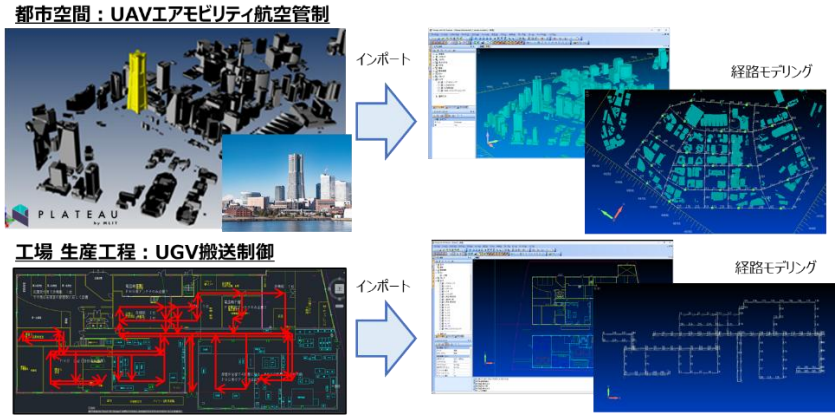

図　３．２．１０−１３　モデリング規約　「IS-Physics 形式モデル」の適用事例

R5 年度採択　安全保障技術研究推進制度　基本設計書を参考に作成。ユーザがマルチエージェント問題に応じてマップモデルを自在に設定可能。同じモデリング規約に従い、UGV2D でも UAV3D でもモデリングが可能である。現状は事前設定が必要であるが、将来は観測情報に基づき動的に生成する計画である。

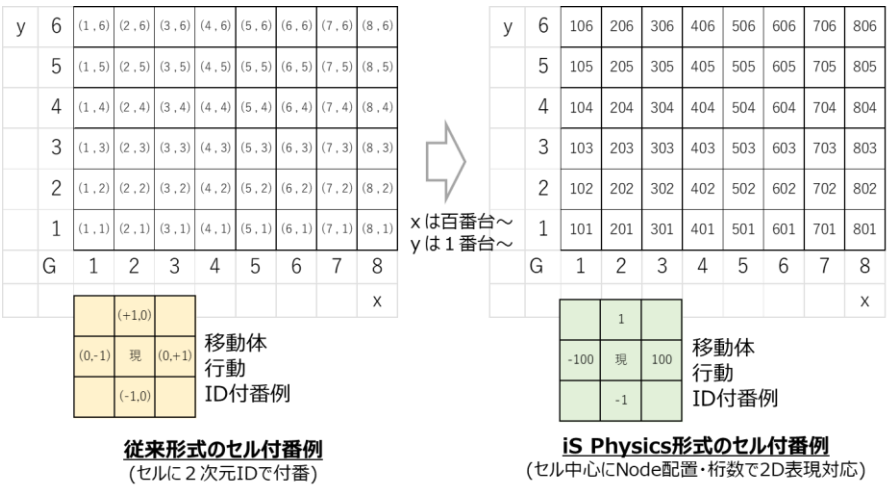

図　３．２．１０−１４　IS-Physics 形式モデルによる２次元 ID 方式への対応例

IS-Physics 形式は、x,y の２次元の ID データを、１次元の ID の桁数で区切って２次元表現する付番ルールを適用。これにより、従来のエージェントの行動表現を、１次元 ID でも２次元 ID 方式と同様の行動表現が可能となる。

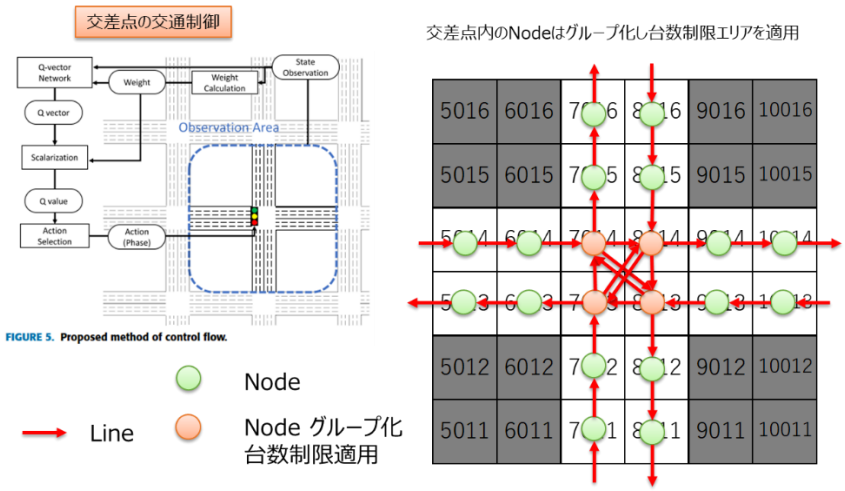

図　３．２．１０−１５　道路交通・交差点の Physics 形式モデリング

IS-Physics 形式は、Node と Line で構成されている。交差点など同時侵入できない場合のモデリングにも対応する。Node グループを定義し、同時侵入許容台数を設定できる。

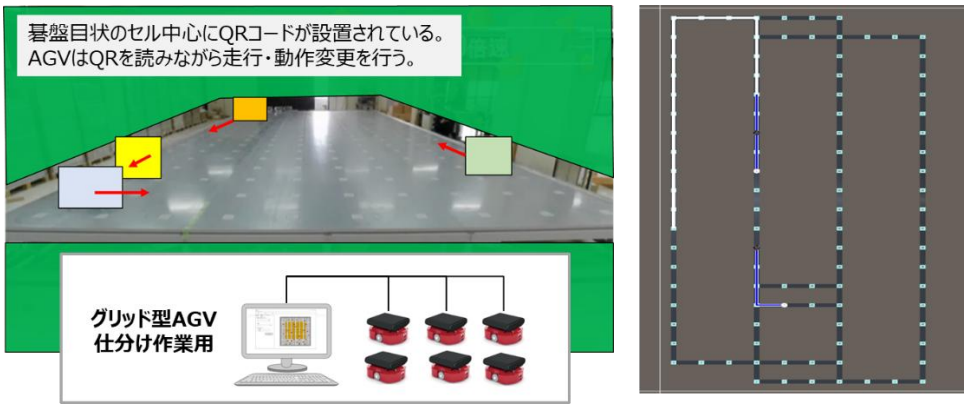

図　３．２．１０−１６　物流倉庫仕分け作業用　グリッド型 AGV　マップモデルへの適用

IS-Physics 形式モデルでは、制御点となる QR コードの設置位置を Node でモデル化。通行ルールを Line で定義。これにより、多台数のグリッド型 AGV の経路計画・交通制御に対応した。また、実機の応答遅延許容するシミュレーション予測制御の実証を行った。

３．２．１１ 汎用マルチエージェント基盤MAARC

MAARC は、無人機群運用の階層型逐次意思決定 AI の実現に向けて、**RCT-OODA 群制御 AI アーキテクチャ**を、次の課題に対応できるよう、AI システム設計論を踏まえて具体化したものである。

- **本質的課題**：資源効率性、身体性、論理性、信頼性、安全性
- **社会実装課題**：汎用性、拡張性・進化性、相互運用性

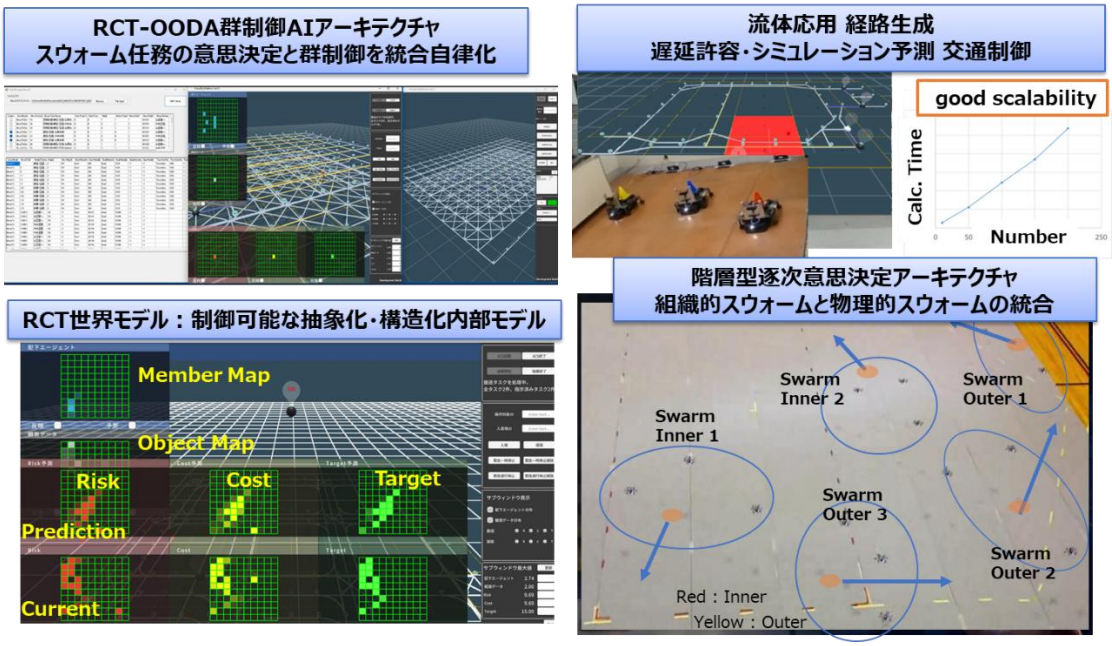

図　３．２．１１-１　MAARC 利用例

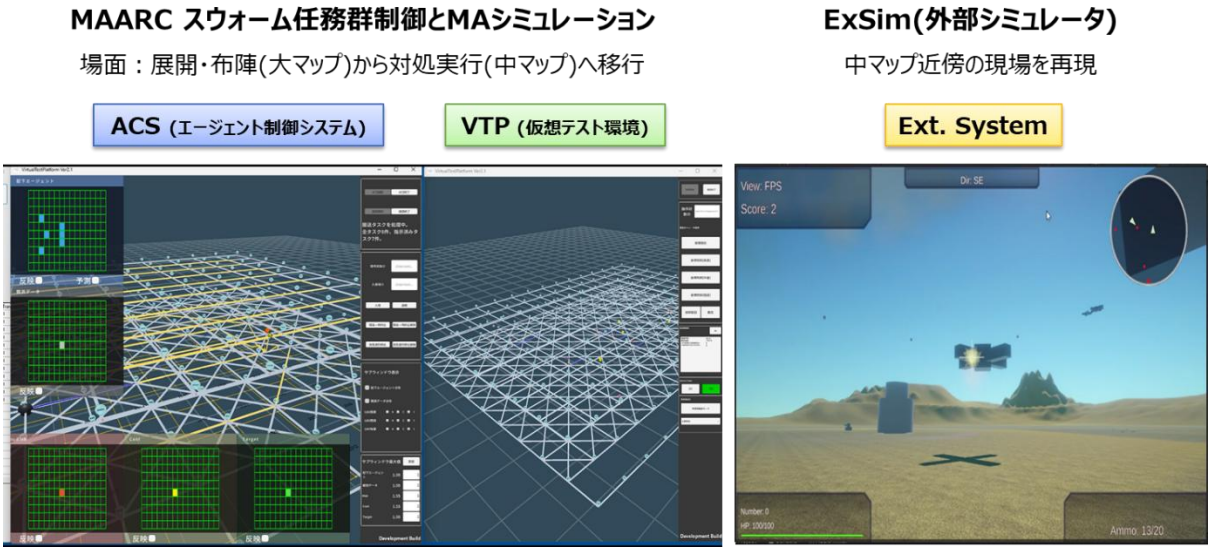

図　３．２．１１-２　MAARC による捜索・救難・警備スウォーム任務実行例

３．２．１１．１ 定義と目的

MAARC（Multi-Agent Architecture for Autonomous Reasoning and Control）は、無人機群の任務遂行における意思決定と群制御の OODA ループを統合的に自律化するために構築された、汎用かつ拡張性の高いマルチエージェント AI 基盤である（図　３．１．２－１７参照）。本基盤は、研究開発から社会実装までを見据え、実機群制御を対象とした評価と運用環境を提供する。

図　３．２．１１－３　MAARC による OODA ループ自律化コンセプト

３．２．１１．２ 社会実装「MAARC三位一体」アーキテクチャ

MAARC(Multi-Agent AI, Robotics CPS, and CAE)三位一体 AI アーキテクチャは、RCT-OODA アーキテクチャを社会実装可能するためのプラットフォームとアプローチを構造化したものである。

本基盤は、以下の**三つの基盤機能**で構成される。

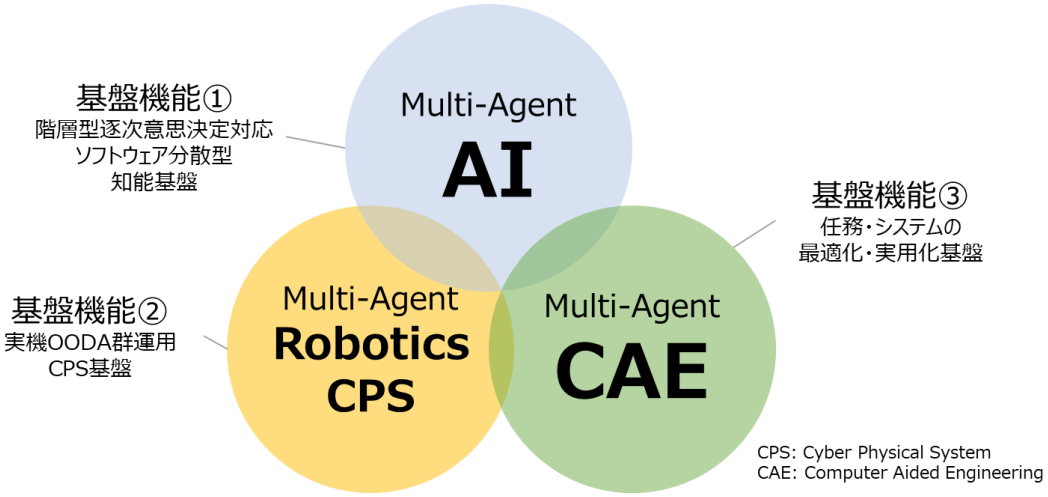

図　３．２．１１－４　MAARC 三位一体アーキテクチャの概念図

（ア）マルチエージェント AI

OODA 群制御 AI と RCT 世界モデルによる分散知能アーキテクチャ

- ソフトウェア分散型 AI アーキテクチャとして、複数エージェントによる認知・判断・行動の協調を実現する（図(2)(ウ)E)-3 参照）。

- OODA 群制御 AI と RCT 世界モデルにより、観測・状況認識・意思決定・行動の OODA ループ全体を統合的に構成。
- ソフトウェア分散・データモデル中心設計を採用し、各エージェントが自律的かつ協調的に OODA ループを実行。

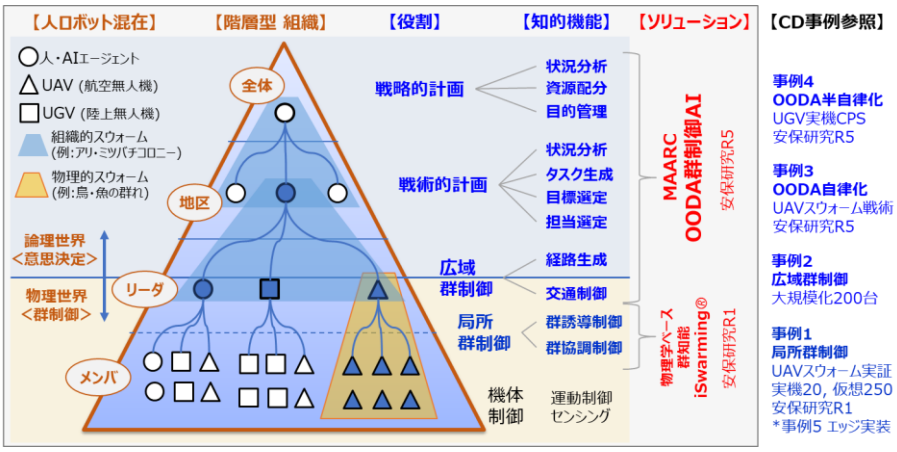

図 ３．２．１１-５　マルチエージェント AI の構成

（イ）マルチエージェント Robotics CPS

実機群の統合運用と遅延許容制御

- AI の身体性を実現し、信頼性・安全性を備える群制御基盤。無人機群の統合運用、通信遅延を許容した制御、リアルタイム連携を支援し、スケール性の高い運用を可能にする。
- 安保研究 R5 において、集中システムに搭載し、仮想環境および一部実環境にて、OODA ループの自律化を実証済み（図(2)(ウ)E)-4 参照)。
- 物理エージェント（UAV・UGV など）に配置された AI がリアルタイムに連携・協調する分散型サイバーフィジカルシステム（CPS）を構築する計画。

✧

✧ 図 ３．２．１１-６　マルチエージェント Robotics CPS 基盤の適用事例

（ウ）マルチエージェント CAE

任務設計・行動計画・最適化評価の統合環境

- 任務モデル設計・行動計画・最適化評価を一体化した構造的かつ説明可能な認知モデルの構築を支援（図(2)(ウ)E)-5 参照)。
- 数理科学・計算工学の知見を応用し、専門的判断の抽象化・可視化手法をマルチエージェント知能設計に導入。

- シミュレーション・検証環境により、AI の信頼性と設計の合理性を担保し、実運用への接続性を高める。

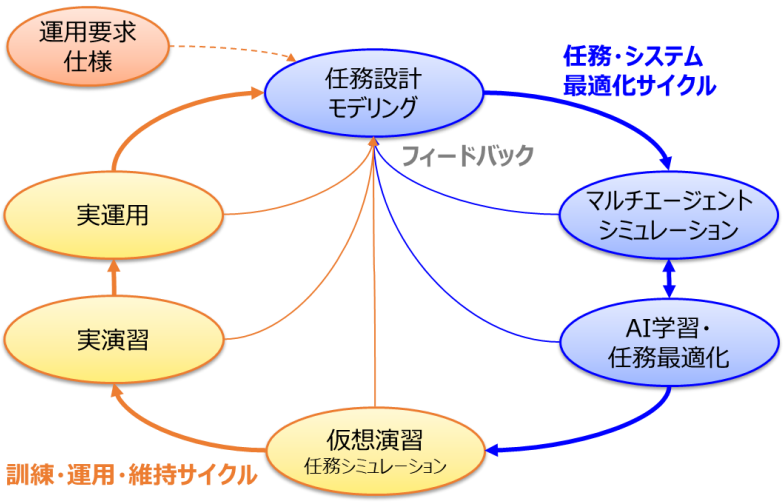

図　３．２．１１－７　マルチエージェント CAE による任務・システムの最適化・実用化コンセプト

３．２．１１．３ ユースケース

本システムのステークホルダー(関係者や関係システム等)との関係を図　３．２．１１－８に示す。関係者は、ユーザとして研究者、任務技術者、運用者が想定される。

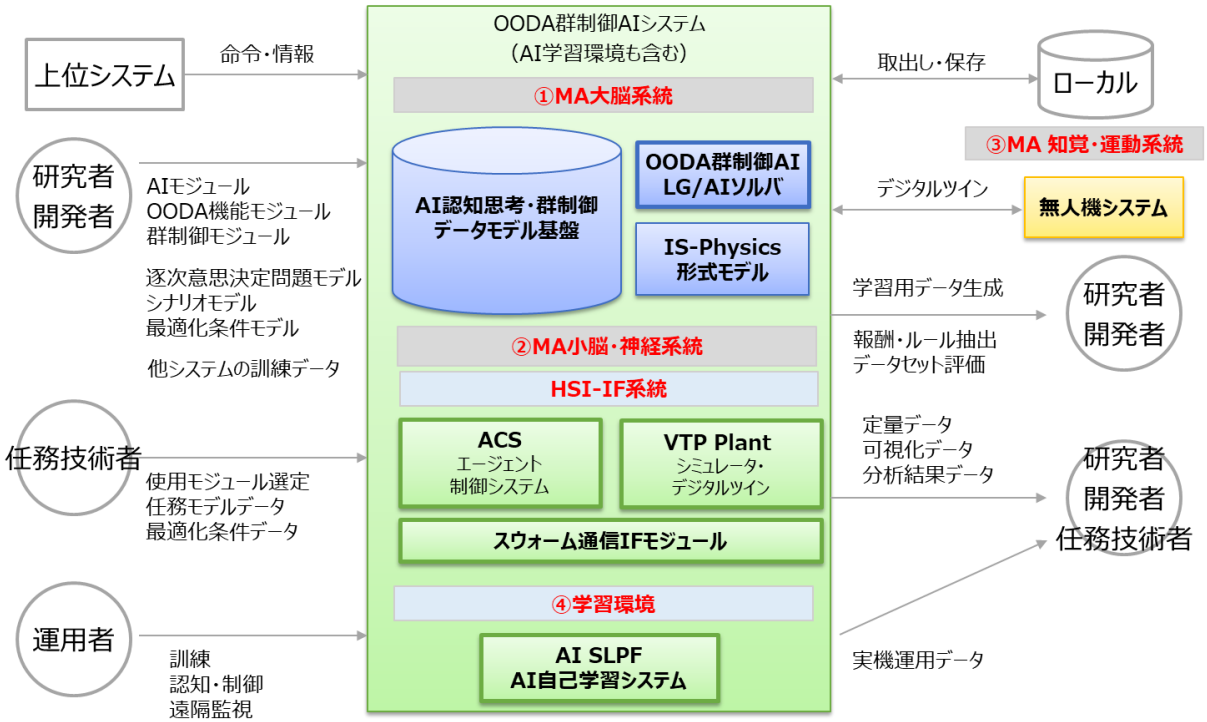

図　３．２．１１－８　ユースケース図

表　３．２．１１-１　利用シーンの概要

フェーズ	利用シーン	主役	利用シナリオ
研究 開発	AI 研究	研究者	研究者は、本システムに独自マルチエージェント AI(MA-AI)を組み込んで、仮想環境や実環境で性能を評価し、AI 研究を行うことができる。MA-AI が制御するエージェントやその運用環境は、本システムの標準モデル(IS-Physics 形式モデル)を用いてモデル化する。これにより、運用環境の構築の手間を省き、研究者は AI 研究に専念することができる。
	モデル開発	開発者	研究者や任務技術者の依頼を受け、無人機や運用環境のモデル化に必要なモデルを設計・実装し、本システムの標準モデルを拡張する。
任務 最適化	任務設計	任務技術者	運用者からヒアリングした任務要求に基づいて、任務設計を行う。設計では、エージェントや MA-AI のパラメータ、エージェントの編成、群制御や認知思考用のマップ等のモデル諸元を設計変数として最適化する。
	モデリング	任務技術者	任務設計に基づいて、運用環境、無人機等のエージェント、及びタスクをモデル化する。また、移動体モデルのカスタマイズが必要な場合は、開発者に依頼し、モデルライブラリに追加されたものを利用する。
	評価 仮想環境	任務技術者	任務設計の評価を仮想環境で行う。具体的には、ACS-VTP Plant を用いてマルチエージェントシミュレーションを行う。結果を分析し、運用者の評価を受けて、要すれば任務設計を見直す。
	評価 実環境	任務技術者	任務設計の評価を運用者の支援を受けて実環境で行う。特に、仮想と実機のギャップを把握し、安全性の確認を行う。実施項目は仮想環境で絞り込み、必要最小限の規模で実機試験を行う。
運用	訓練 仮想環境	運用者	最適化が完了した環境で、実務利用の準備として、任務責任者や操縦担当者等の運用者が、仮想環境で訓練を行い、操作・運用に完熟する。
	訓練 実環境	運用者	最適化が完了した環境で、実務利用の準備として、任務責任者や操縦担当者等の運用者が、実機環境で訓練を行い、操作・運用を完熟する。
	実運用	運用者	訓練を受けた運用者が、実務に使用する。運用データは取得され、研究開発にフィードバックされる。

３．２．１１．４ システム構成

（１）　システム構成

MAARC のシステム構成を以下に示す。

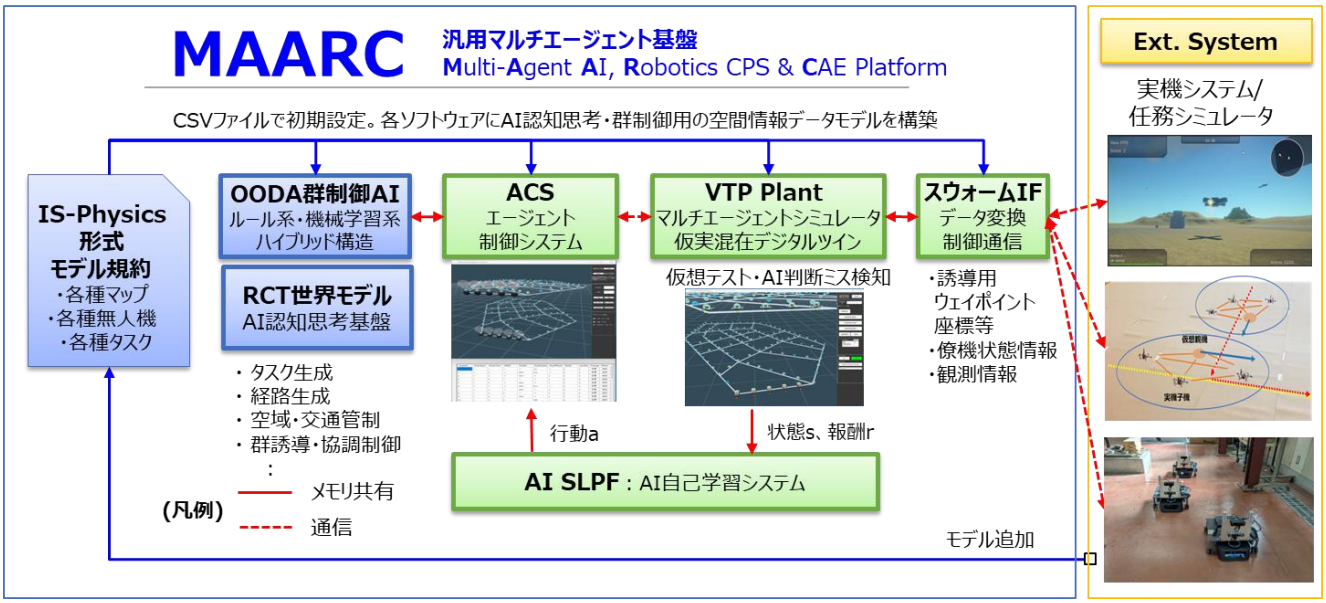

図　３．２．１１-９　MAARC システム構成

（２）　サブシステムの概要

MAARC は以下のサブシステム群から構成される。

- **IS-Physics 形式データモデル**：任務世界、無人機諸元、タスク等の諸元を統合記述する標準仕様。AI モデルと物理構造の整合を保証する。

- **OODA 群制御 AI**：マルチエージェント AI の一種である。配下の複数の UxV やスウォームを使い OODA による任務を遂行するシステムである。マルチエージェントの意思決定、多数のエージェントやスウォームに対する配車計画、経路生成、交通空域管制、及び誘導制御等の広域を俯瞰した群制御を行う。

- **ACS (Agent Control System)**：エージェント制御システムの略。AI が生成する制御コマンドを受け、実機エージェントまたは仮想化エージェントを制御する。また、配下エージェントの観測情報を受け取り、AI にフィードバックする。

- **VTP (Virtual Test Platform)**：Virtual Test Platform for Plant の略。仮想移動体シミュレーションと実機リアルタイムデジタルツイン表示の二つの役割を兼ねる CPS (サイバーフィジカルシステム)環境である。仮想移動体が ASC 制御情報を受け応答を再現する。実機移動体の応答を、デジタルツインとして取り込み、ACS の制御情報を中継する。実機または仮想の移動体応答を ACS にフィードバックする。

- **スウォーム IF**：外部システムと接続するデータ変換、通信インターフェース。座標系変換、データ変換等を行い、相互運用性を高める。

- **AI SLPF (AI Self Learning Platform)**：AI の学習と性能評価のための実験環境。

- **HSI UI**：ACS-VTP に組み込まれた GUI は、認知負荷・操作負荷を低減し、HSI (Human Swarm Interaction) を支援する。

（３） 利用場面

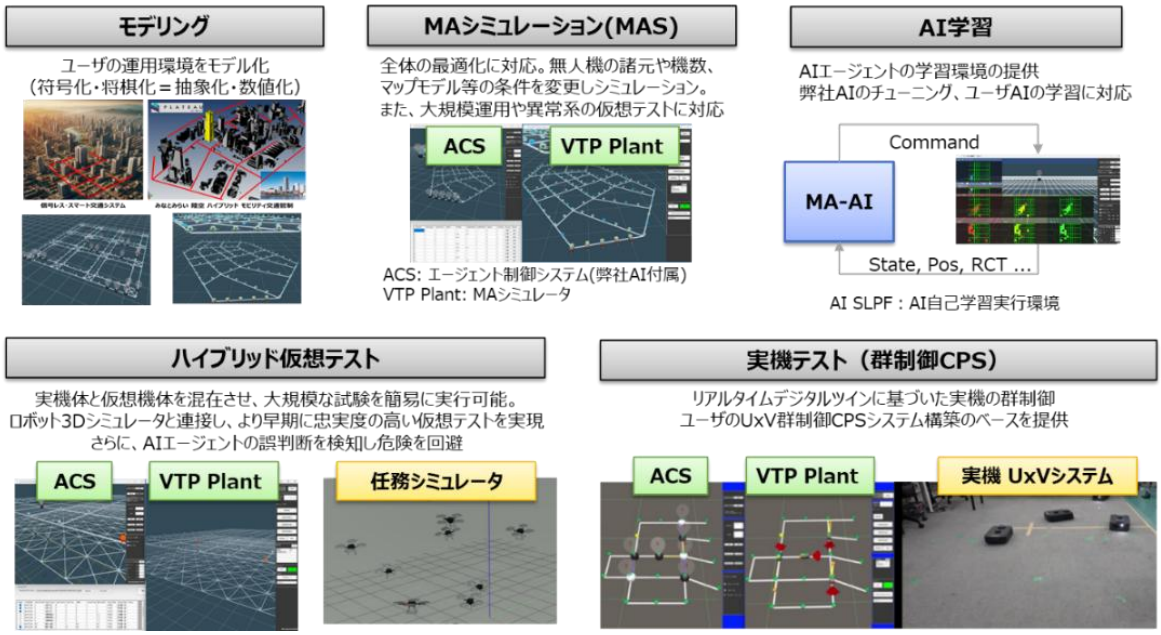

図 ３．２．１１－１０　MAARC の利用場面

３．３　実施項目②AIソルバの構築

３．３．１ 成果概要

結論：OODA群制御AIにおけるロジック支援型AIは、信頼性・適応性・最適性を兼ね備えたアーキテクチャとして機能し、複合AI設計が動的状況に対応した全体最適化を実現できることを仮想テスト試験により評価実証した。

目的：OODA群制御AIの中核要素である複合AI設計について、以下の２点を評価目的とした。

1. ロジック支援型AIの複合AI設計が、信頼性の源泉として実際に機能するか。(図　３．１．２-２３、表　３．１．２-７、表　３．１．２-８参照)
2. 動的状況変化を踏まえた全体最適化が、有効に働くかどうか

手法：スマート交通システム(図　３．１．２-２５参照)を評価シナリオとし、所定の搬送オーダーに対するスループット最適化(総搬送時間)を評価指標とした。比較対象として、以下の3構成による経路生成戦略を設定し、同条件下で性能比較を行った。

1. 距離最小化・ルールベースAI単体：静的な最短距離経路を生成(評価基準)
2. Path上混雑度考慮・時間最小化・ルールベースAI単体：
3. Path上混雑度考慮・時間最小化・ロジック支援型AI：
4. Area内混雑度考慮・時間最小化・ルールベースAI単体：
5. Area内混雑度考慮・時間最小化・ロジック支援型AI：

ここで、ルールベースAIの時間最小化経路生成は、経路生成時、移動体密度を移動コストに付加し、最小時間の経路を探索する方式をとっている。

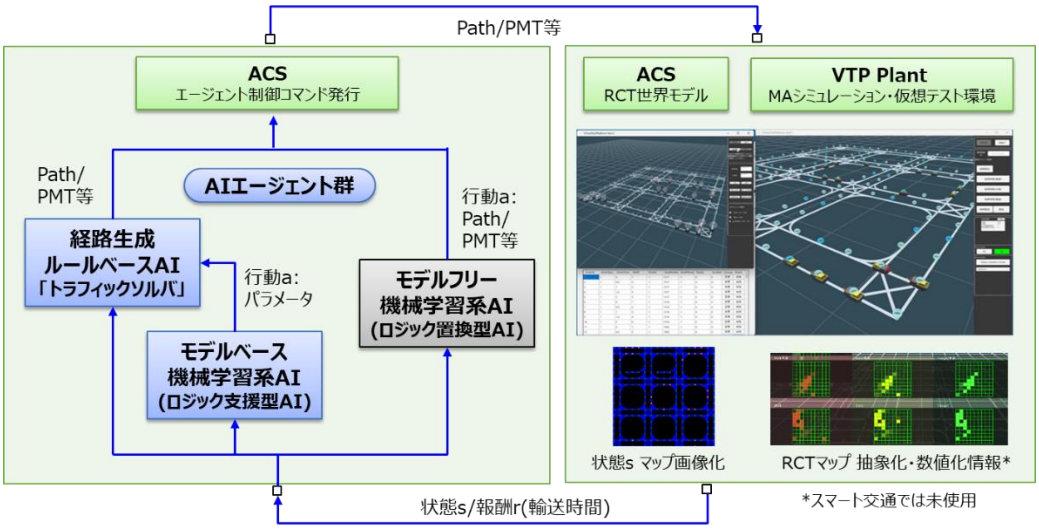

図　３．３．１-１　AI 学習環境

表　３．３．１-１　AI モデル構成

AI種類	モジュール・モデル	内容
ルールベースAI	トラフィックソルバ	経路生成の二方式を最適化対象とする。 ・方式１：Pathベース経路生成 ・方式２：Areaベース経路生成
機械学習系AI	DQN強化学習	方式１、２の渋滞考慮係数を最適化する。

表　３．３．１－２　機械学習系 AI の入出力条件

項目	内容	備考
状態s	経路マップ、各無人機の位置情報	画像データ
報酬r	ステップ報酬：ステップ内オーダーの搬送完了時間 エピソード報酬：総搬送時間	１エピソードNステップ 報酬付与はステップ毎
行動a	トラフィックソルバの渋滞考慮係数 (Path基準、Area基準)	

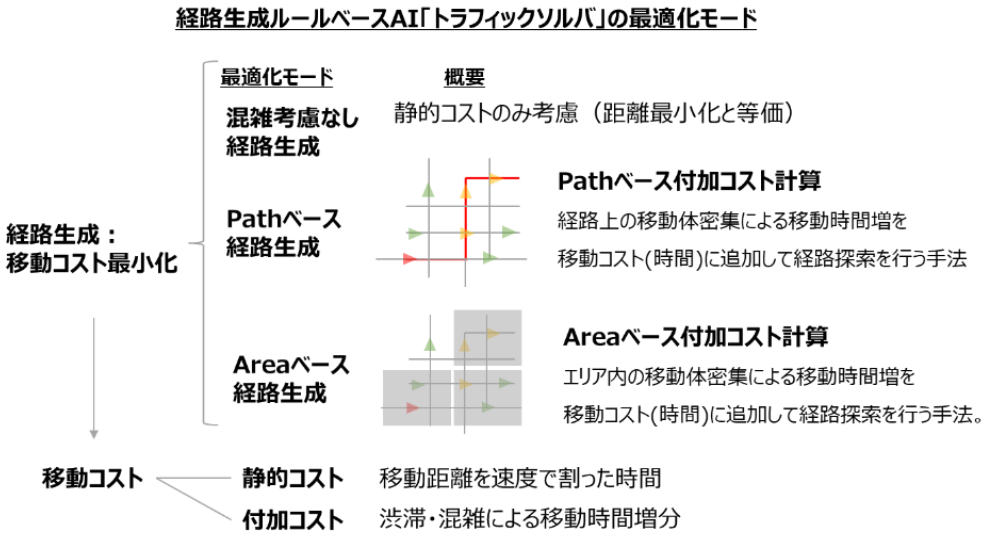

図　３．３．１－２　経路生成ルールベース AI「トラフィックソルバ」の最適化モード

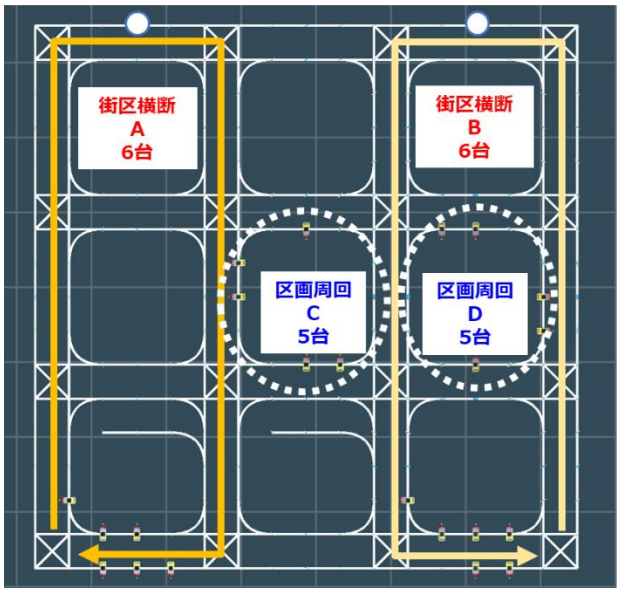

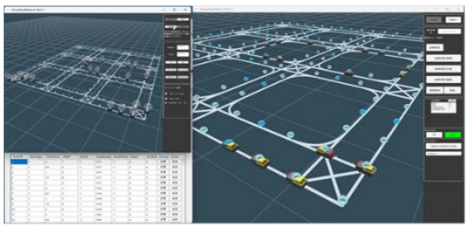

任務種類	チーム	台数	タスク数
街区横断	A	6台	54
	B	6台	54
区画周回	C	5台	140
	D	5台	140

図　３．３．１－３　スマート交通経路モデル

結果：検証の結果、複合AI構成は以下の観点で優れた性能を示した（表　３．１．２－９参照）。

- 状況適応性の向上：
  ・動的な交通状況や混雑状況に柔軟に対応し、オーダー遂行にかかる時間を低減
  Path基準：ルート上の混雑度を考慮した経路生成により、7.1%の時間短縮を達成
  Area基準：エリア内の混雑度を考慮した経路生成により、14.1%の時間短縮を達成
- 運用安定性の確保：

・ルールベースの予測可能性を活かしつつ、機械学習AIにより動的対応能力を強化

- 全体最適化の有効性：
  ・複数オーダー・複数車両の同時運用においても、スループット最適化に効果を発揮

以上により、OODA群制御AIにおける複合AI設計は、実環境下でも実効性を発揮するアーキテクチャであり、信頼性・適応性・運用最適性の三要素を高水準で両立可能であることが確認された。

表　３．３．１－３　機械学習系 AI の入出力情報と最適化結果

経路生成方式	AI構成	ステップ数・ タスクリスト分割数	平均総搬送時間 単位:秒（比率）	備考
混雑考慮なし 移動時間最小化	**ルールベースAI**	**１ステップ・分割なし**	**498.7 (100)**	**基準**
Pathベース経路生成 Path上混雑考慮 移動時間最小化	ルールベースAI	１ステップ・分割なし	478.6 (95.9)	
	ロジック支援型AI (ルールベース ＋DQN複合AI)	２ステップ・２分割	485.3 (97.3)	
		３ステップ・３分割	463.5 (92.9)	効果あり
Areaベース経路生成 Area内混雑考慮 移動時間最小化	ルールベースAI	１ステップ・分割なし	428.4 (90.2)	
	ロジック支援型AI (ルールベース ＋DQN複合AI)	２ステップ・２分割	426.7 (89.9)	効果あり
		３ステップ・３分割	**407.8 (85.9)**	**効果あり**

３．３．２ システム概要

ゲーム AI、マルチエージェント制御の調査を行い、機械学習モデルと学習環境を整理した。次に、OODA 群制御 AI モデルとその学習環境である ACS-VTP Plant との連携の検討を行い、アーキテクチャ設計を行った。以下に概要を示す。詳細は基本設計書(関連資料)を参照のこと。

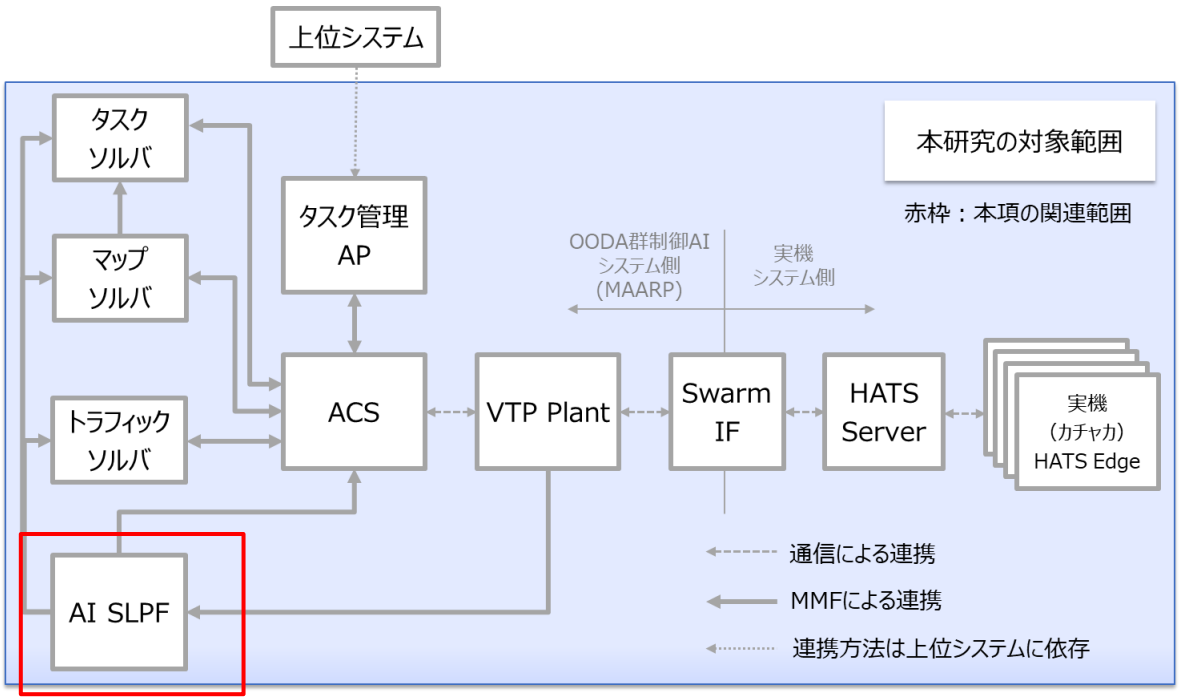

図 ３．３．２－１ システム概要図

本項に関連する部分を赤枠で示す。

３．３．３ AI学習環境の構築

３．３．３．１ 学習環境への要求

学習環境は、競合型不完全情報ゲームをプレイするマルチエージェントAIの研究支援のため、表 ３．３．３－１に示す要求に対応できることが求められる。

表 ３．３．３－１ AI 学習環境への要求項目

項目	要求概要
AI 研究支援	AI 研究者の本システムの利用場面を示す。 研究者は自作の AI モジュールやマルチエージェント制御モジュールを評価・検証するため、これらを ACS に組み込んでシミュレーション環境や実機環境での性能評価を行う。 研究者は、対象問題の運用空間やエッジエージェントをモデル化する必要があり、そのために標準モデルライブラリが利用できる。 標準モデルは、諸元を変更するだけで使用可能で、モデルの追加や機能拡張も容易である。
競合型不完全情報ゲーム対応	シミュレータは、複数の AI によるアクセスが可能であること。 異なる AI が独立して空間情報を認知できるマップモデルを備えること。 評価関数や価値関数のベースとなる情報をシミュレータから取得できること AI SLPF が生成した方策を、ACS を介して AI モジュールに反映できることが 実機テスト環境のデータから、仮想テスト環境と同様の評価用データを取得できること

３．３．３．２ 学習環境のシステム構成

学習環境は、強化学習に必要な状態s、報酬rをVTP Plantから取得できること、AIが生成した行動aをACSに反映できることが必要となる。また、実環境のデータから、仮想環境と同じ評価用データを取得できることが必要となる。上記要求を満たす学習環境の概要を、表 ３．３．３－２に示す。

表 ３．３．３－２ AI 学習環境システムの概要

項目	システム概要
仮想環境による AI 学習環境システム構成 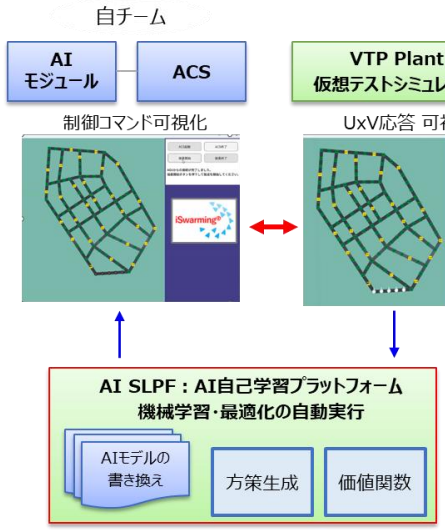	AI が生成した行動を、ACS を介して仮想テストシミュレータの配下エッジエージェントに伝えてマルチエージェントシミュレーションを行う。また、AI SLPF は、VTP Plant から学習に必要な情報を取得し、強化学習を行う。具体的には、VTP Plant は、状態データや評価関数用データを出力する。AI SLPF はその出力データを取り込み、評価関数等を計算し、方策を生成する。ACS は、方策を受信し、制御演算を行い、VTP Plant のエージェントを制御する。
実環境による AI 学習環境システム構成	ACS が VTP Plant と HATS を介して実機を制御する。VPT Plant は中継のみで、実質的には、ACS と HATS により実機を遠隔制御して

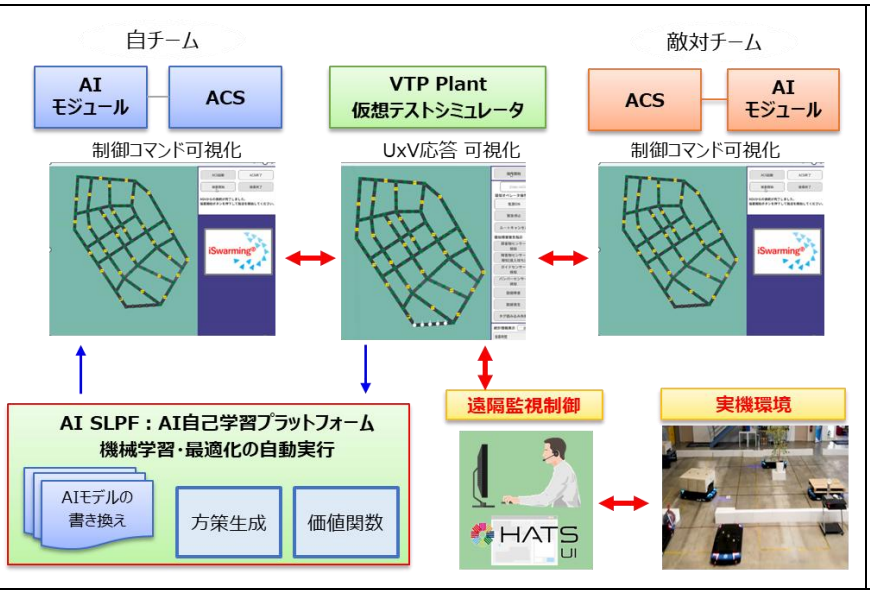

いる。VTP Plant を介した理由は、Sim2Real 問題(仮想と実機の差異問題)の分析・評価の容易化のためである。これにより、AI の学習は、仮想テスト環境でも実機テスト環境でも、同じ過程で行うことができる。

３．３．３．３ AI学習フロー

学習対象のゲーム(シナリオ)の種類毎にAI学習のフローを以下に示す。検討の参考として、現状と最適化のデータフローを併せて示す。

（１） 完全情報ゲームのシミュレーション

AI学習環境のデータフローの検討のベースとして示す。シミュレーションモデルは入力ファイルに定義される。仮想テスト環境は、シミュレーションモデルを読み込んで解析を実行し、エッジエージェントのトラフィック、生産性指標・統計情報を出力する。

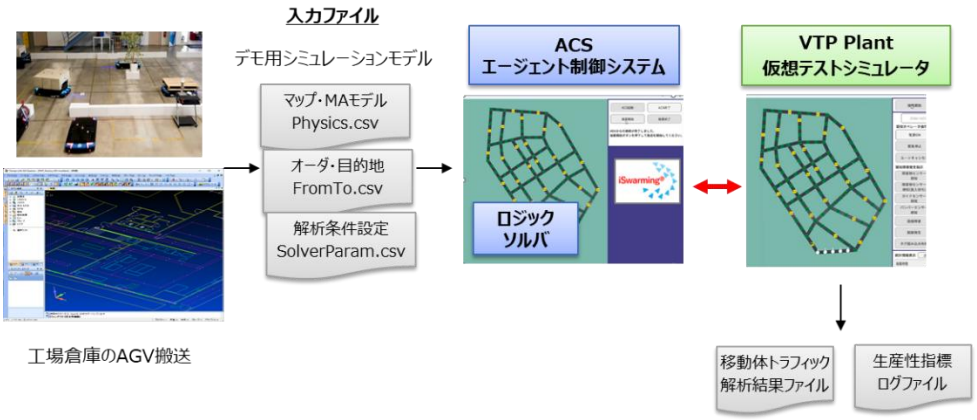

図 ３．３．３－１ 現状のマルチエージェントシミュレーション環境

（２） 完全情報ゲームの最適化

最適化は、出力データ(ファイル)から目的関数を評価し、最適化アルゴリズムに従って設計変数を変更し、入力ファイルを書換え、再度シミュレーションを実行するループ(イタレーション)を回しながら、目的関数を最大化または最小化する設計変数の組合せを探索する。このループを回すのが最適化ツールである。

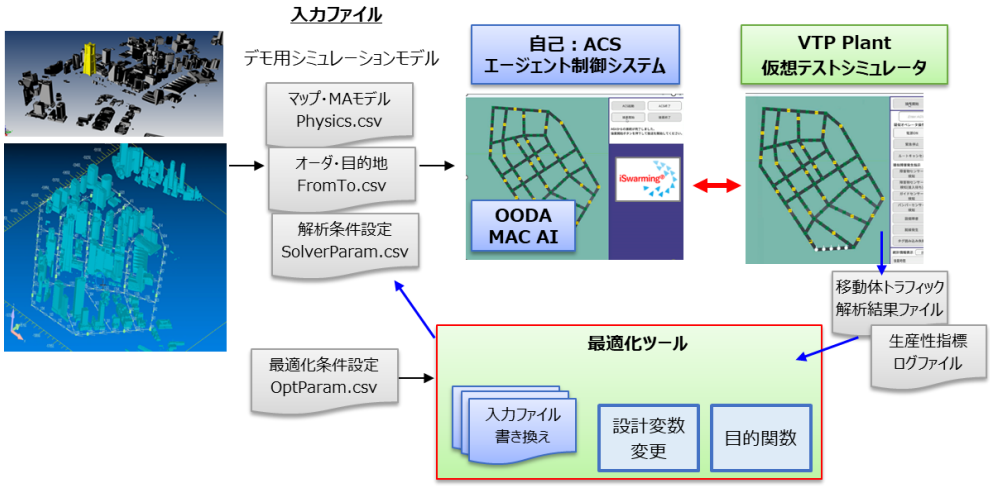

図　３．３．３－２　最適化フロー

（３）　完全情報ゲーム AI 学習

完全情報ゲームのAI学習ループは、最適化ループと似ている。差異は、最適化はファイルベースに目的関数や設計変数を操作するのに対し、AI自己学習はソフトウェア内部データから評価関数・価値関数を計算し、方策を生成しエージェントを操作する。

要件は、エージェントを制御する側のシステムとエージェントの応答を再現するシミュレータの内部データを、AI自己学習プラットフォームを取得できることが要件となる。

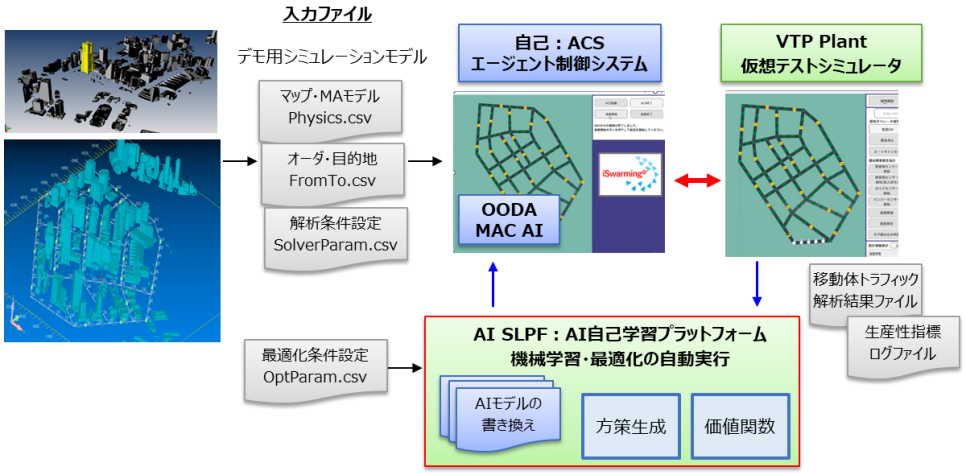

図　３．３．３－３　完全情報ゲームの AI 学習フロー

（４）　不完全情報ゲーム AI 学習

不完全情報ゲームのAI学習ループは、完全情報ゲームのループと同じである。差異は、敵対側のエージェントがシミュレータ内で動作するが、その情報は自チーム側のエージェントが観測した結果を状態データとして取得することである。

要件は、敵対チームの情報をシミュレータ上の観測により、自チームの制御システム側に取り込んで、AI学習プラットフォームに入力する状態情報として利用できることとなる。

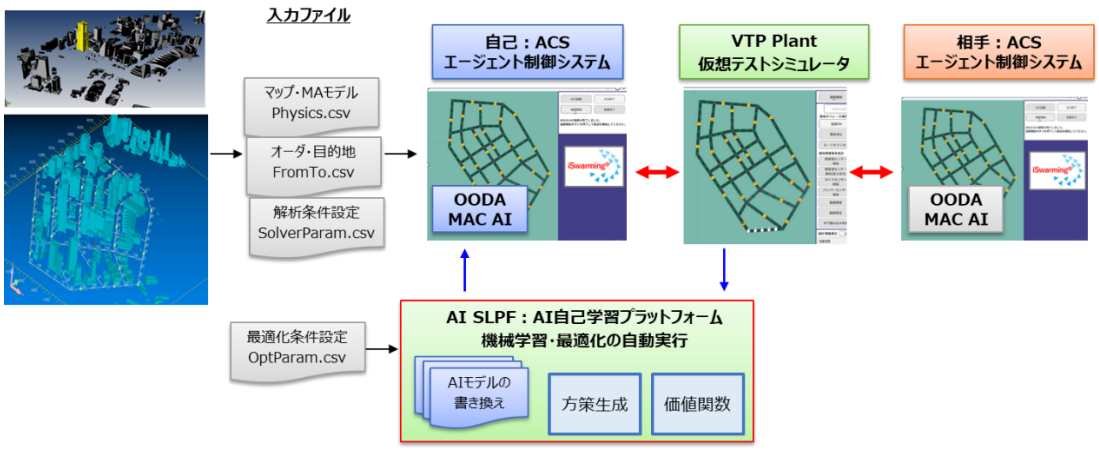

図　３．３．３－４　不完全情報ゲームの AI 学習フロー

（５）　実環境の AI 学習

実環境では、ACSの制御コマンドに基づいて実機が制御される。ACSと実機の間にはVTP PlantとHATSが介在する。実機テスト環境はHATSを介してVTP Plant上にデジタルツインを構成する。これによりSim2Real問題(仮想と実機の差異問題)の分析・評価の容易化のためである。AIの学習は、仮想テスト環境でも実機テスト環境でも、同じ過程で行うことができる。

要件は、AI SLPFは、実機テストの結果を用いた学習が可能であること、シミュレーションで学習したAIを実機テストで評価できることが要件となる。また、そのようなIFを有すことも要件となる。

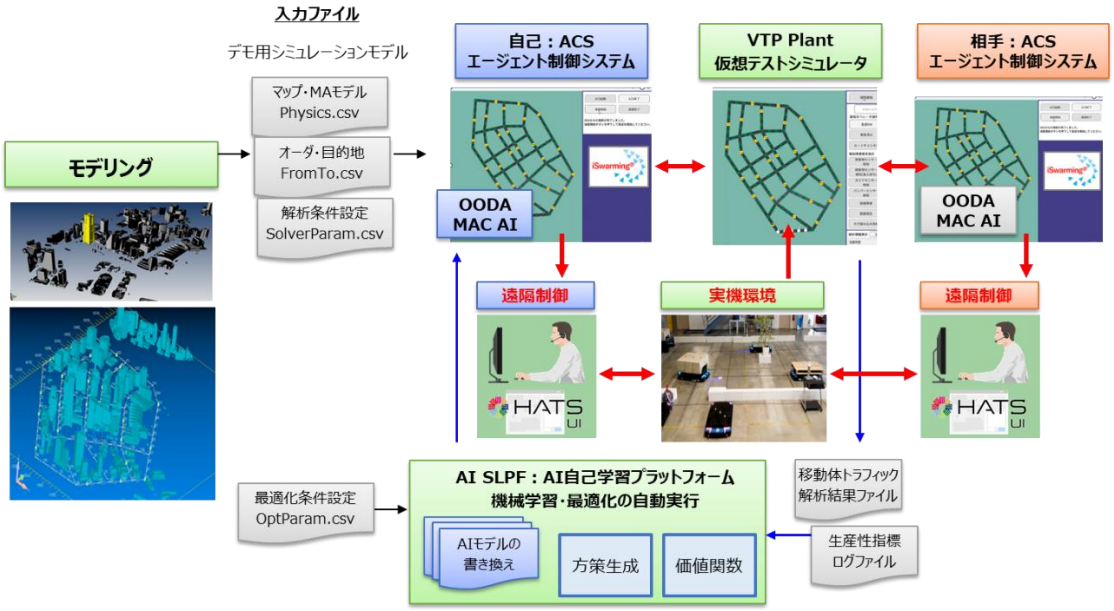

図　３．３．３－５　実機テスト環境による AI 学習フロー

３．３．３．４ 学習環境のソフトウェア間データインターフェース

AI SLPF(AI自己学習プラットフォーム)は、ACSやVTP Plantと相互作用して、学習を行う。本項では、弊社の安保研究R5の検討成果を引用し、要件検討を行う。

（１）　用語・概念の明確化

はじめに用語と概念を図　３．３．３－６に示すように明確化する。AI用語の「エージェント」

は意思決定主体を意味する。AI用語の「エージェント」は、マルチエージェント問題では「ACS及びマルチエージェントAIの中央エージェントを指す。マルチエージェント問題の運用環境側のエッジエージェントは、AI用語の「環境」に含まれる概念である。

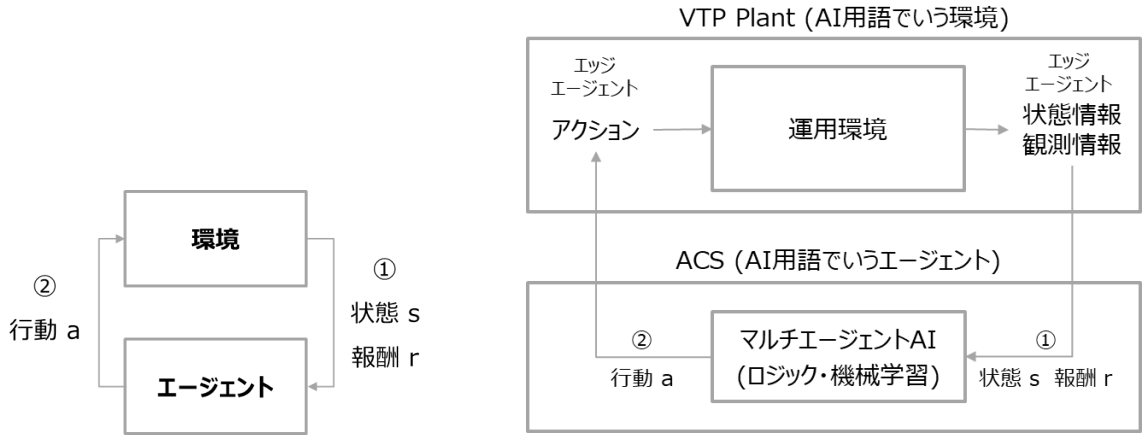

図 ３．３．３−６　AI 学習に関する用語・概念図

逐次意思決定 AI は、マルコフ決定過程を対象とする。マルコフ決定過程は、自分の行動次第で次の状態が決まる世界である。強化学習では、エージェントは環境から状態と報酬を受け取り（①）、それに基づいて次の行動を決定する（②）。目的を達成するまでこのサイクルを繰り返す。ここで、意思決定および行動の主体のことを「エージェント」と呼ぶ。エージェントと相互作用を行う対象のことを「環境」と呼ぶ。「相互作用」とは、エージェントと環境が互いに情報の送受信を行うことを指す。「エピソード」とは、強化学習で解きたいタスクの開始から終了までの期間をいう。「ステップ」とは、エージェントと環境の相互作用（情報の送受信）が行われる回数のことを言う。

３．３．４ AIソルバアーキテクチャ

本項では、AIソルバアーキテクチャの設計思想や作業方針について示す。AIソルバに使用するAIモデル等の調査検討は、第（４）項に後述する。

（１） AI 設計思想

OODA群制御AIシステムのAIアーキテクチャの設計思想は、表 ３．３．４－１に示すように、思想１と思想２のふたつある。思想１は、ロジックベースのロジックソルバのパラメータ調整をAIで行うパラメータの自律最適化である。モデルベース強化学習等を適用する。思想２は、ロジックソルバそのものをAIで置換するコンセプトである。

思想１への期待は、高い AI 信頼性と性能向上の両立である。それを可能とするのが、最適化と強化学習のハイブリッド適用である。強化学習と最適化は、表 ３．３．４ ２に示すように、強化学習はエージェントが環境と相互作用して学習するフレームワークであり、最適化は与えられた問題において最適な解を見つける手法である。強化学習は学習と探索が組み合わさり、未知の状態でも有効である一方、最適化は問題の定義が明確であることが前提とされる場面で威力を発揮する。マルチエージェントの逐次意思決定問題は、未知状態であるが、ロジックソルバにより問題の定義が明確であるため、両者ハイブリッド適用は、AI 信頼性と性能向上の両立が可能となる。

思想２への期待は、性能のブレークスルーである。問題のモデルが白紙の状態から、学習により理想的なモデルが得られる。判断材料のマップ情報等の分析により信頼性も得られることが機体できる。参考として、強化学習と類似性が高い計算力学の構造トポロジ最適化技術の結果評価をアナロジーとして利用する。トポロジ最適化は、設計空間の塊から理想的な構造骨格(荷重パス)を導出し、構造性能のブレークスルーを実現する技術である。その仕組みは、部材の応力が低い部分を彫刻を削るように削除し形を導出する。数理的なモデルは行列式であり、弾性率を低くすることで荷重パスの導出を実現している。この手法が強化学習に似ている。

表 ３．３．４－１ AI 設計思想

種類	思想１	思想２
名称	LGパラメータ自律最適化(動的最適化)	LG完全置換
概要	ロジックソルバのパラメータ調整をAIで行う。	ロジックソルバそのものをAIで置換する
フロー	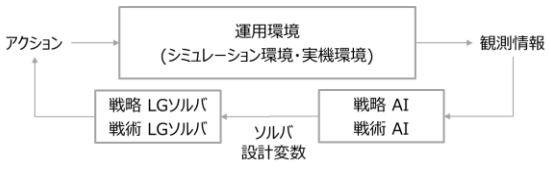	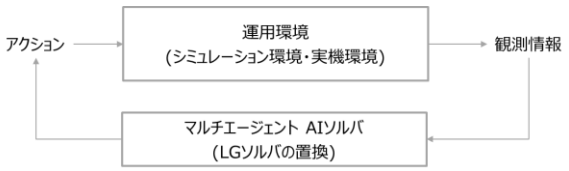
期待	高いAI信頼性と性能向上の両立 ベースのLGソルバは従来比で性能が向上	性能のブレークスルー AI信頼性は判断材料マップ情報の可視化で対応

表 ３．３．４－２　最適化と強化学習の比較

項目	最適化	強化学習
目的	最適化の目的は、与えられた問題において目的関数を最小化または最大化する変数のセットを見つけることです。最適化は、与えられた制約のもとで最適な解を見つける問題に焦点を当てています。最適化は、数学的な問題やシステムの設計など、様々な領域で利用されます。	強化学習の目的は、エージェントが環境と相互作用しながら、与えられたタスクにおいて報酬を最大化するような方策を学習することです。強化学習は、エージェントが未知の環境で意思決定を行い、学習を通じて最適な行動を見つけ出すことを目指します。
入力	最適化は通常、目的関数の勾配や制約条件を利用して、解の探索を行います。最適化は目的関数の微分可能性が前提とされることが多く、通常は初期解から反復的に探索を進めることが一般的です。	強化学習では、エージェントが行動を選択した結果として得られる報酬に基づいて学習が行われます。エージェントはフィードバックを通じて自らの行動を修正し、最適な方策を学習します。
問題のモデル化	最適化は通常、問題の定式化が十分に行われ、目的関数や制約条件に対する情報が事前に与えられています。環境や問題に対するモデルが既知の場合が多いです。	強化学習は、エージェントが未知の環境と相互作用する場面が一般的です。エージェントは環境のダイナミクスを知らない場合があり、経験を通じて学習していきます。
適用範囲	最適化は様々な分野に適用されます。機械学習のモデルの最適化、制約の下での資源割り当て、製造プロセスの最適化などがあります。	強化学習は主に動的な環境での意思決定に適しています。例えば、ゲームプレイ、ロボット制御、自動運転などが挙げられます。

（２）　作業方針

AI学習環境の構築は、表 ３．３．４－３及び表 ３．３．４－４に示すように、実用シナリオにそって段階を踏んで実施する。はじめに環境構築のため簡易なモデルにより学習サイクルを回すことを優先する。準備が整ったら、より高度なAIを作っていく方針である。

表 ３．３．４－３　実用シナリオについて

シナリオ	No.	内容
実用シナリオ１ 工場倉庫の AGV 搬送	(1)	・交通全体最適：渋滞を考慮した AI を作成
	(2)	・突発事象対応：未知要素に対応した AI を作成
実用シナリオ２ 重要拠点の UxV 遠隔監視	(1)	・災害初動対応：災害初動対応の AI を作成
	(2)	・域内警戒監視：侵入者の検知と追跡に対応した AI を作成

表 ３．３．４－４　環境構築手順

経路マップ	作業ステップ	概要
簡易モデル	ステップ１	手動で強化学習を実行
	ステップ２	自動で強化学習を実行
	ステップ３	MMF を用いて動的にパラメータを変更・取得し自動で強化学習を実行
評価モデル	ステップ１	（本ステップは環境構築用のため省略する）
	ステップ２	自動で強化学習を実行
	ステップ３	MMF を用いて動的にパラメータを変更・取得し自動で強化学習を実行

（３） AI フェイルセイフ設計・判断根拠の見える化への対応

AIフェイルセイフ設計・判断根拠の見える化の観点(図 ３．３．４－１参照)からロジックソルバとAIソルバは、並列であることを想定していた。AI設計思想で示したように、AI適用はロジックを最適化する思想１、ロジックを置換する思想２の適用とする。両者を比較し、信頼性の観点から適用を決めていく。ロジックソルバの演算フローは、図 ３．３．４－２に示す構造となっており、AIフェイルセイフ設計と判断根拠の見える化に対応したアーキテクチャとしている。

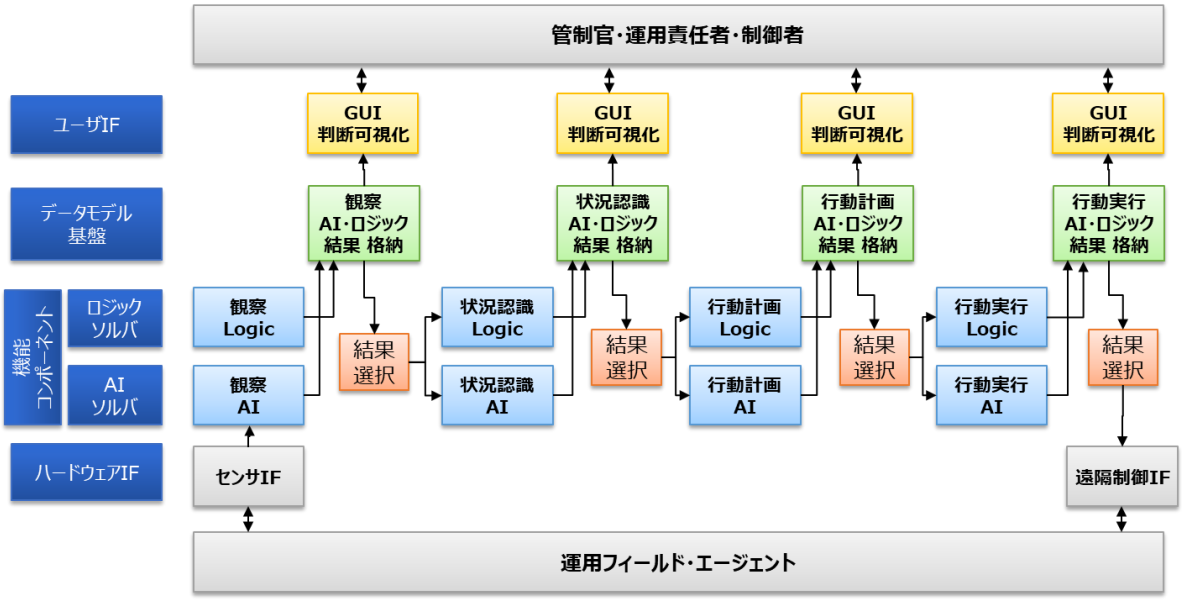

図 ３．３．４－１ AI フェイルセイフ設計・AI 軽量化・判断根拠の見える化の概念図

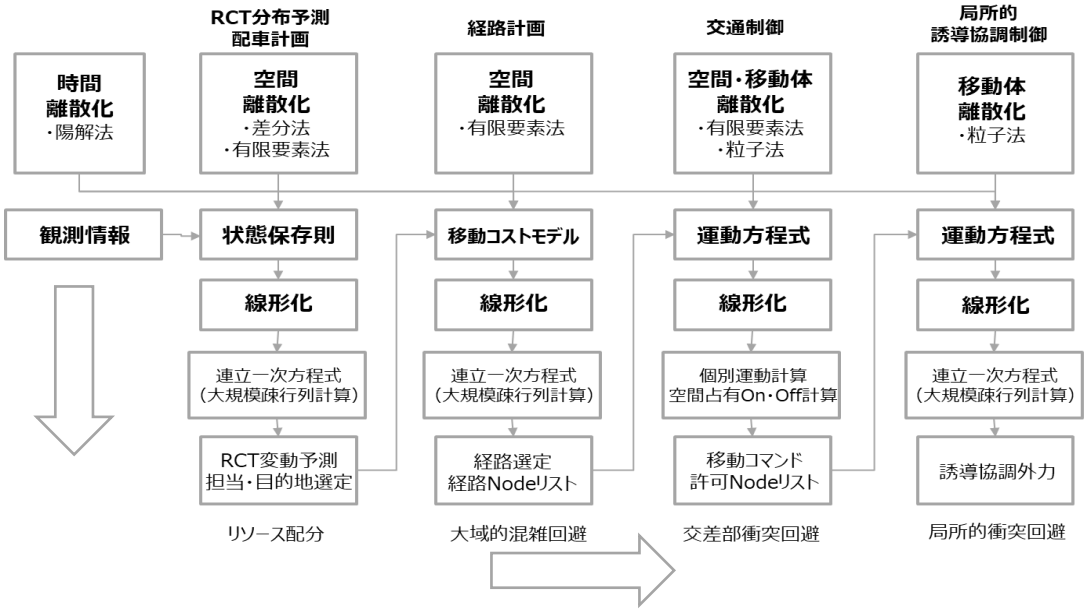

図 ３．３．４－２ ロジックソルバの OODA 意志決定群制御フロー

３．３．５ 機械学習モデルの調査

ゲーム AI、マルチエージェント技術の調査を行い整理した成果を、関連資料・基本設計書の「調査報告書_AI ソルバ関連_240508.docx」にまとめた。本項では概要を示す。

（１） ゲーム AI

現在この領域は発展目覚ましく、この他にも続々と新しいアプローチが発表されている。その中でも、最新の手法である強化学習がゲームAIに与えた影響は非常に高い。本研究でも強化学習の適用を行う。

（ア）概要

ゲームAIは非常に広範にわたる。ゲームAIを形作る主要な技術やアプローチを下記に示す。順番はおおむね古いものから順に記述している。

表 ３．３．５－１ ゲーム AI のアプローチ手法一覧

No.	項目	概要
1.	スクリプティング(Scripting)	特定の行動やイベントを手動でプログラムする。
2.	状態マシン(State Machines)	キャラクターの振る舞いを状態（State）で管理し、イベントに応じて状態間を遷移させる。
3.	経路探索(Pathfinding)アルゴズム	A*(エースター)、ダクストラ法、ナビゲーションメッシュ(Navmesh)など。
4.	意思決定ツリー(Trees)	条件に基づき行動を決定するツリー構造。
5.	インフルエンスマップ(Influence)	ゲーム世界の各部分に影響力の合いを割り当て、それに基づいて行動を決する。
6.	フェイズド行動セット(Phased Behavior Sets)	特定のフェーズにおける行動パターン集合。
7.	ベイジアンネットワーク(ayesian Networks)	不確かな情報を基に確率的な推論を行うネットワーク。
8.	遺伝的アルゴリズム(Genetic Algorithms)	自然選択の原理に基づいた最適化手法
9.	ユーティリティベースAI(Utility-based AI)	様々な行動の有用性を数値で評価し、最も有用な行動を選択する。
10.	エージェントベースモデリング(Agent-based Modeling)	各々のエージェントが独自の行動規則に従って行動する。
11.	ニューラルネットワーク(Neural Networks)	機械学習を用いて大量データから学習する。
12.	シミュレーションベースAI(Simulation-based AI)	ゲームの状態をシミュレーションし、その結果に基づいて行動を選する。
13.	強化学習(Reinforcement Learning)	試行錯誤を通じて最適な行動を学習。

（イ）強化学習の利用

強化学習とは収益（報酬の合計）最大化のために状態に応じて行動を選択することである。強化学習を行うためには図 ３．３．５－１に示すように状態s、行動a、報酬rを定義する必要がある。そして方策πはベルマン方程式により導かれ、環境Eはマルコフ決定過程に従う。

また、本研究で事前調査した「AlphaStar」も強化学習が使用されており、本AIアーキテクチャの参考としている。関連するAlphaシリーズのゲームAIを表 ３．３．５－２に示す。

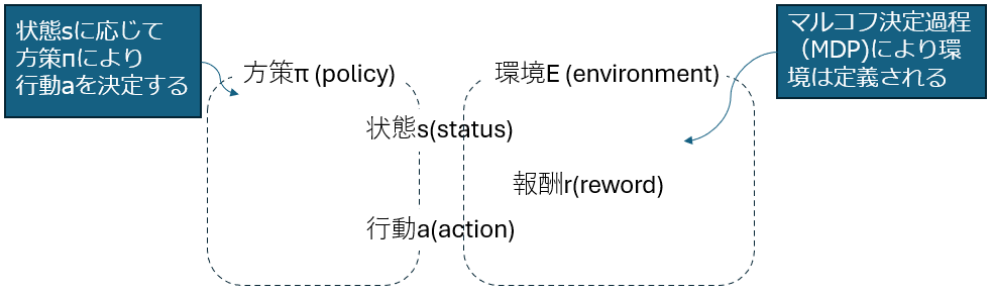

図　３．３．５－１　強化学習の全体像

表　３．３．５－２　DeepMind 社ゲーム AI の強化学習適用例

No	項目	概要
1.	AlphaGo	人間のプロ囲碁プレイヤーに勝利したことで有名なAI。ディープラーニングとモンテカルロ木探索を組み合わせた手法で、囲碁における新しい時代を築いた。
2.	AlphaGo Zero	AlphaGoの後継として開発されたAIで、人間の棋譜データを一切使わず、ゼロから自己対局によって学習を進め、AlphaGoを上回る強さを示した。
3.	AlphaZero	AlphaGo Zeroのアプローチを一般化し、囲碁だけでなく、チェスや将棋にも応用できるようになったAI。各種ボードゲームにおいて、既存のトップレベルのAIや人間の世界チャンピオンを圧倒した。
4.	AlphaStar	リアルタイム戦略ゲーム「StarCraft II」でプロのプレイヤーを破ったAI。複雑な戦略とマルチタスクが求められるゲームで、高いレベルのプレイを達成した。
5.	MuZero	AlphaZeroのアプローチを拡張し、ゲームのルールを事前に知らない状態から学習を始めることができるAI。チェス、将棋、囲碁、さらにはアーケードゲームにおいても強力な性能を発揮した。

（２）　マルチエージェント技術

（ア）概要

結論としては、 表　３．３．５－３に示すように、LLMやChatGPTで世間的にも高い成果を上げているトランスフォーマーを利用したMATが最も優れた性能を発揮しているため、本研究ではMATの実装を目標とする。

表　３．３．５－３　マルチエージェント強化学習モデル比較表

モデル	処理速度	性能	競争タスク	実装難易度
DQN	○	×	△	◎
COMA	○	×	×	△
MADDPG	○	×	○	△
VDN	○	△	×	○
QMIX	△	△	△	○
QTRAN	△	△	×	△
QPLEX	△	△	△	△
MAPPO	△	○	×	△
HAPPO	△	○	○	△
MAT	△	◎	◎	△

備考）実装難易度は、公開情報の多寡を主観的に評価したものである。

（イ）強化学習の調査まとめ

群制御の代表技術であるマルチエージェント技術には、主にアルゴリズムベースのものと、強化学習ベースのものが存在する。アルゴリズムベースの代表的なものであるマルチエージェ

トパスファインディング(MAPF)アルゴリズムと、強化学習ベースのマルチエージェント強化学習について調査した。アルゴリズムベースのマルチエージェントパスファインディングにおけるSOTA(現時点での最高性能)モデルであるLaCAMを調査し、マルチエージェント強化学習では、DQN～MATまでを調査した。

調査内容の概要を表 ３．３．５－４及び表 ３．３．５－５に示す。詳細は、関連資料・基本設計書の「調査報告書_AIソルバ関連_240508.docx」を参照のこと。

表 ３．３．５－４　マルチエージェント強化学習(MARL)手法の分類

項目	概要
中央集権型学習 -中央集権型実行	環境内にエージェントは複数いるが、各エージェントの方策を出力するモデルは単一で、モデルへの入力も、各エージェントの観測をまとめて受け取る設定。方策モデルの処理能力に左右され、個別エージェントの観測の情報の共有が無制限という仮定が必要。(AlphaStar 等)
分散型学習 -分散型実行	一番難しい設定で、全てのエージェントが学習/テスト時ともに個別の観測を受け取って学習・行動する。深層学習以前のマルチエージェント強化学習や、DQN 登場直後の問題設定はこれ。IQL (Independent Q-Learners)としてまとめられることも。
中央集権型学習 -分散型実行	現在の MARL の主流設定。学習時に追加の中央情報を使うが、テスト時は分散的。

表 ３．３．５－５　中央集権型学習・分散型実行 (CTDE) モデル一覧

項目	概要
COMA	(Counterfactual Multi-Agent Policy Gradients) CTDE が導入された手法で、シングル RL の方策勾配を CTDE で改良。
MADDPG	(Multi-Agent Deterministic Policy Gradients) DDPG を CTDE で改良。
VDN	価値分解型手法の元祖、各エージェントの個別価値の和と CTDE の勾配計算時に用いる共同価値を一致させる。
QMIX	最もよく使われる MARL の代表的アルゴリズムで、Hypernetwork ベースの Mixing network で共同価値を計算。
QTRAN	IGM 原理が提唱された手法で、共同価値を学習しやすい形に変換。
QPLEX	シングル RL でも使われた Dueling Network を使用し、個別価値と共同価値の両方に Dueling Network の機構を組み込む。
MAPPO	(Multi-Agent Proximal Policy Optimization) シングル RL でよく使われる PPO を、学習アルゴリズムはそのままにハイパラや実装を MARL 向けに調整した手法で、MARL で重要とされてきた IGM 原理を満たさず、役割学習などの機構も持たないが、既存の MARL アルゴリズムを圧倒する性能を発揮
HAPPO	(Heterogeneous-Agent Proximal Policy Optimization) MAPPO はアルゴリズムの性質上、全てのエージェントが同じパラメータを共有する。Homogeneous な設定でしか使用できない。この設定は Parameter Sharing と呼ばれる MARL における代表的な工夫。行動空間が違うエージェントで構成される MARL のタスクでも MAPPO のようなやり方で学習するため、HAPPO を提案。新たに Advantage Decomposition という概念と、それをベースにした sequential policy update を PPO に取り入れた。
MAT	HAPPO で提案された Advantage Decomposition と Sequential Policy Update をベースに、MARL の行動生成・学習を系列モデリングとして定式化。(論文タイトル:Multi-Agent Reinforcement Learning is A Sequence Modeling Problem) 系列モデリングの最強手法である Transformer を取り入れることで、 MARL の様々なタスクで圧倒的な性能を発揮している。さらに、Transformer が得意とする事前学習についても検討を行い、MARL でエージェント数が違うタスクへの Few/Zero-shot 学習が成功することも証明。

（３） 機械学習モデル

調査内容の概要を表 ３．３．５-６に示す。詳細は、関連資料・基本設計書の「調査報告書_AIソルバ関連_240508.docx」を参照のこと。

表 ３．３．５-６ 機械学習モデル一覧

項目	概要
DQN	Deep Q-Network（DQN）は、DeepMindによって開発された強化学習のアルゴリズムで、2015年に自然言語処理に関する論文で発表されました。このアルゴリズムは、従来のQ学習に深層学習の技術を組み合わせることで、高次元の入力空間を持つ複雑な環境での学習を可能にしたのが特徴です。 DQNは、強化学習における深層学習の応用の先駆けであり、その後の多くの進化したアルゴリズム（例えばDouble DQN、Dueling DQNなど）に影響を与えています。 強化学習にディープラーニングを応用した最初期に出現した最も有名なモデルで、構造も分かりやすく、情報も整備されており、実装がしやすい。膨大なリソースが割ければ高い性能も引き出せるポテンシャルがあるが、洗練されておらず学習に膨大な工数を要する旧来のモデルである。
VDN	Value Decomposition Networks（VDN）は、マルチエージェント強化学習のためのアルゴリズムで、特に協力的なタスクにおいて、複数のエージェントが共有するグローバルな報酬を最大化するために設計されています。VDNの目的は、各エージェントの行動価値関数（Q関数）を個別に学習し、それらを線形に組み合わせることで、全エージェントの合同行動価値を推定することです。 VDNは、マルチエージェント強化学習における価値分解のアプローチの中でも基本的なものであり、より複雑な相互作用をモデル化するための発展的な手法（例えばQMIXやQMIXの拡張版など）に影響を与えています。 マルチエージェント強化学習で最初期に出現したモデルで、構造もシンプルかつ計算コストも低く実装しやすい。その反面マルチエージェント性能は限定的。
QMIX	QMIXは、マルチエージェント強化学習の文脈で使用されるアルゴリズムで、特に協力的なタスクにおいて複数のエージェントが共同で目標を達成することを目指しています。単一エージェントの強化学習アルゴリズムが個々のエージェントに焦点を当てるのに対し、QMIXはエージェント間の相互作用と全体の目標を考慮に入れた方法です。 QMIXはマルチエージェント強化学習の中でも特に注目されているアプローチの一つであり、多くの研究者によってさらなる改良や新しい応用が模索されています。 性能もある程度期待できるが、MATほどではない。
MAT	「Multi-Agent Transformer」は、トランスフォーマー（Transformer）モデルをマルチエージェント強化学習（MARL）の文脈で応用したものです。トランスフォーマーは、もともと自然言語処理（NLP）の分野で開発されたアーキテクチャで、近年では様々なシーケンシャルデータを処理するタスクに応用されています。 トランスフォーマーの核心的な概念は、自己注意（self-attention）メカニズムです。これは、入力されたデータの各要素が他の全要素との関連性を計算し、それに基づいて情報の集約を行う仕組みです。この特性は、複数のエージェントがそれぞれの状態と他のエージェントの状態を同時に考慮する必要があるMARLにおいて特に有用です。

３．３．６ AIソルバ(機械学習系AI適用)の研究

OODA 群制御 AI の機械学習系 AI を AI ソルバと称している。その学習環境を AI SLPF と称している。

本項は、AI ソルバの研究内容の構成を示す。研究は、以下に示す構成にて実施した。各項目の詳細は、関連項を参照のこと。

AI ソルバの研究は、環境構築、性能評価試行、性能評価の三段階で実施した。実施内容は、下表に示す通りである。

【AI 研究の構成】　　関連項

AI 性能評価・・・スマート交通シナリオ

ロジック支援型 AI(思想 1、モデルベース機械学習)　　３．３．７項

表 ３．３．６-１　研究に使用したマップ・任務シナリオ

環境構築・性能評価試行	AI 性能評価:全体最適化	AI 性能評価:未知環境対応
環境構築用簡易マップ	スマート交通シナリオ	災害救難・警備シナリオ
三分岐１重周回マップ	３ｘ３街区マップ	＊未実施(中止)
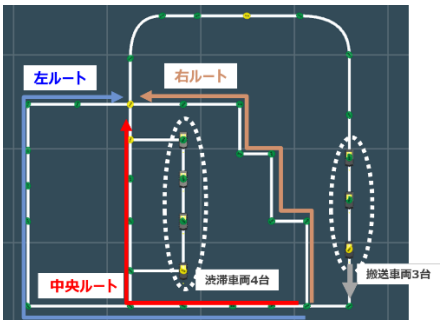	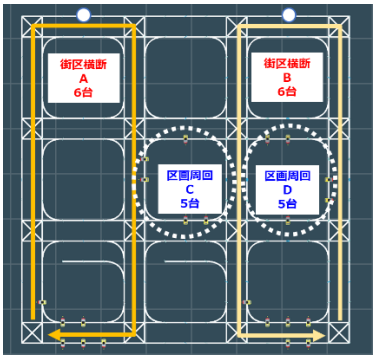	

３．３．７ AI性能評価：スマート交通シナリオ・ロジック支援型AI(モデルベース機械学習)

３．３．７．１ 概要

評価 MAP と呼ばれる３×３ブロックで構成された環境に設定し、AI で渋滞考慮係数を最適化することにより、操業時間がどのように変化するか検証することを目的としている。

下期で最適化する渋滞考慮係数は Path 基準と Area 基準の２つが存在しており、Path 基準向け最適化 AI 開発、 Area 基準向け最適化 AI 開発の２パターンで実施する。

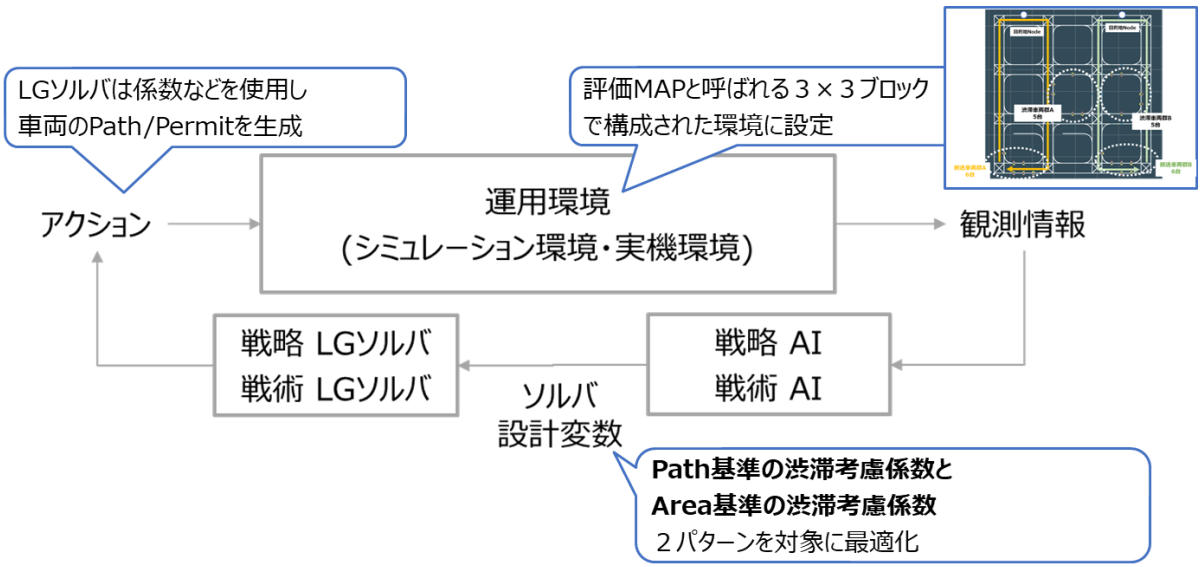

図 ３．３．７－１ AI 設計思想と評価マップにおける思想１の AI 学習環境の対応関係

また、今回は評価マップと呼ばれる環境で検証した。マップの Node 配置は 3*3 のグリッドになっており、渋滞車両が 10 台、搬送用車両が 12 台存在し、搬送車両にはマップ反対にある目的地 Node を経由する形で 2 周するタスクが与えられている。

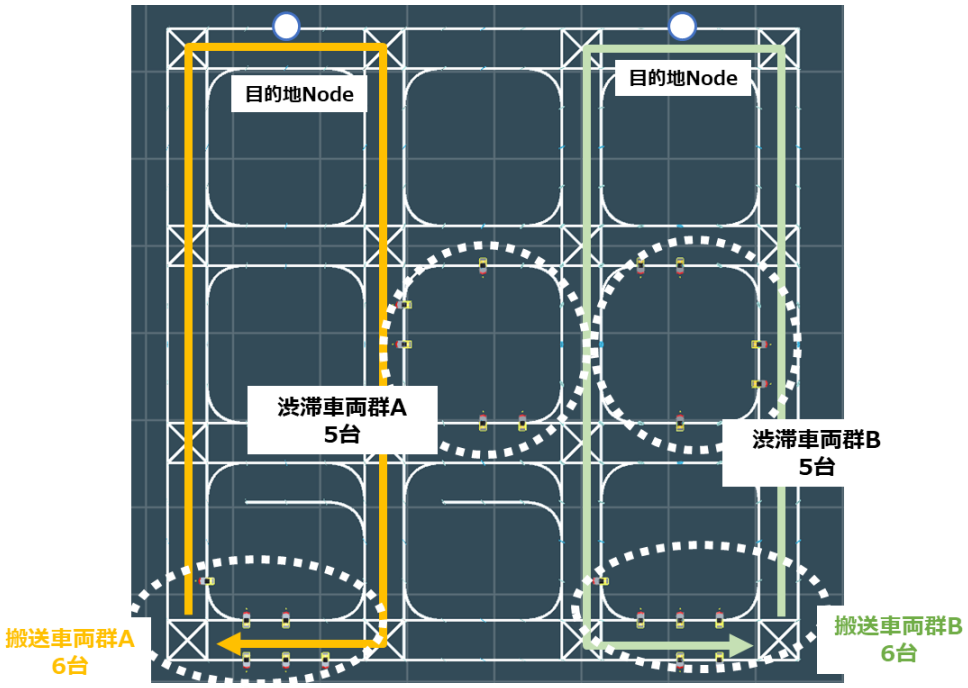

図 ３．３．７－２ 評価マップ全景

Path 基準向け最適化 AI 開発と Area 基準向け最適化 AI 開発の成果は以下の通り。
各開発は別マシンで実施しているため、渋滞考慮無しの操業時間が異なる。
Path 基準向け最適化 AI 開発では最大 7.1%の操業時間の短縮があった。
Area 基準向け最適化 AI 開発では最大 14.1%の操業時間の短縮があった。

表　３．３．７－１　Path 基準向け最適化 AI 開発の成果概要

名称	説明	平均	標準偏差	評価比率	参照
渋滞考慮無し	評価基準になる操業時間	498.7	7.7	100	ANPOR5_中間評価_AIチーム報告まとめ_241007_思想1.xlsx
ランダム実行	ランダムに行動を1000回与えた際の平均操業時間	478.6	11.7	95.9	
エピソード3分割	オーダ数でエピソードを3分割し行動を3回実行	463.5	11.1	**92.9**	
エピソード2分割	オーダ数でエピソードを2分割し行動を2回実行	485.3	10.5	97.3	

表　３．３．７－２　Area 基準向け最適化 AI 開発の成果概要

名称	説明	平均	標準偏差	評価比率	参照
渋滞考慮無し	評価基準になる操業時間	474.5	8.5	100	ANPOR5_中間評価_AIチーム報告まとめ_241007_思想1.xlsx
ランダム実行	ランダムに行動を1000回与えた際の平均操業時間	428.4	24.2	90.2	
エピソード3分割	オーダ数でエピソードを3分割し行動を3回実行	407.8	6.3	**85.9**	
エピソード2分割	オーダ数でエピソードを2分割し行動を2回実行	426.7	24.6	89.9	

３．３．７．２ AI学習環境の研究成果

Path 基準向け最適化 AI 開発と Area 基準向け最適化 AI 開発の成果は以下の通り。各開発は別マシンで実施しているため、渋滞考慮無しの操業時間が異なる。

Path 基準向け最適化 AI 開発では最大 7.1%の操業時間の短縮があった。
Area 基準向け最適化 AI 開発では最大 14.1%の操業時間の短縮があった。

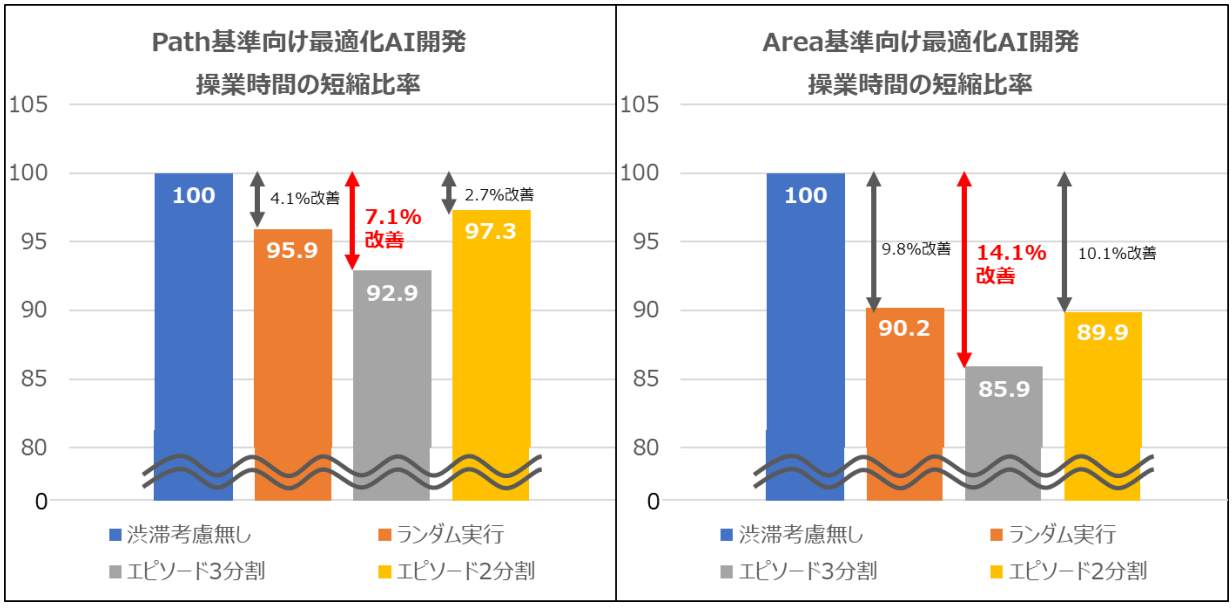

図　３．３．７－３　各開発区分における操業時間の短縮比率

（１） Path 基準向け最適化 AI 開発における研究成果

渋滞考慮無しの操業時間を基準値とすると、35.2 秒、評価基準値を 100 とした比率で 92.9 と 7.1%の改善がみられた。また、エピソードを 2 分割にした場合は評価比率が 97.3 と悪化する結果となった。

これは Area 基準向け最適化 AI 開発でも同様の結果であることから、分割数による影響が大きいと推測される。

また、ランダム実行と比べた場合でも 3%の改善があるため、小さいながら改善傾向が見て取れる。

表 ３．３．７－３ Path 基準向け最適化 AI 開発における研究成果

名称	説明	平均	標準偏差	評価比率	参照
渋滞考慮無し	評価基準になる操業時間	498.7	7.7	100	ANPOR5_中間評価_AIチーム報告まとめ_241007_思想1.xlsx
ランダム実行	ランダムに行動を1000回与えた際の平均操業時間	478.6	11.7	95.9	
エピソード3分割	オーダ数でエピソードを3分割し行動を3回実行	463.5	11.1	92.9	
エピソード2分割	オーダ数でエピソードを2分割し行動を2回実行	485.3	10.5	97.3	

AI が推定した行動 a(渋滞考慮係数)の内訳を表す。

エピソード 3 分割ではエピソード内で全て同じ行動 a を選択しているのに対して、エピソード 2 分割では行動 a が大きく 2 分されている。エピソード 3 分割は、エピソードを分割したのにも関わらずすべての行動が同じになってしまっていることからエピソード全体で最適な渋滞考慮係数を選択していると考えられる。また、エピソード 2 分割でエピソード 3 分割で推定された「エピソード全体で最適な渋滞考慮係数」が推定されていないことから、学習が不完全であることが考えられる。

表 ３．３．７－４ Path 基準向け最適化 AI 開発(エピソード 3 分割) 推定 100 回結果

1回目の行動	2回目の行動	3回目の行動	選択回数	平均操業時間
(18.0, 0.0, 1.0)	(18.0, 0.0, 1.0)	(18.0, 0.0, 1.0)	100	463.6

表 ３．３．７－５ Path 基準向け最適化 AI 開発(エピソード 2 分割) 推定 100 回結果

1回目の行動	2回目の行動	選択回数	平均操業時間
(11.0, 0.0, 9.0)	(11.0, 0.0, 9.0)	1	494.2
(11.0, 0.0, 9.0)	(4.0, 0.0, 11.0)	45	487.9
(17.0, 0.0, 16.0)	(4.0, 0.0, 11.0)	49	483.0
(13.0, 0.0, 15.0)	(4.0, 0.0, 11.0)	5	477.9

（２） Area 基準向け最適化 AI 開発における研究成果

渋滞考慮無しの操業時間を基準値とすると、66.7 秒、評価基準値を 100 とした比率で 85.9 と 14.1%の改善がみられた。また、エピソードを 2 分割にした場合は評価比率が 89.9 と悪化する結果となった。

これは Path 基準向け最適化 AI 開発でも同様の結果であることから、分割数による影響が大きいと推測される。

表　３．３．７－６　Area 基準向け最適化 AI 開発における研究成果

名称	説明	平均	標準偏差	評価比率	参照
渋滞考慮無し	評価基準になる操業時間	474.5	8.5	100	ANPOR5_中間評価_AIチーム報告まとめ_241007_思想1.xlsx
ランダム実行	ランダムに行動を1000回与えた際の平均操業時間	428.4	24.2	90.2	
エピソード3分割	オーダ数でエピソードを3分割し行動を3回実行	407.8	6.3	85.9	
エピソード2分割	オーダ数でエピソードを2分割し行動を2回実行	426.7	24.6	89.9	

下記に AI が推定した行動 a(渋滞考慮係数)の内訳を表す。

エピソード 3 分割ではエピソード内で全て同じ行動 a を選択しているのに対して、エピソード 2 分割ではすべてのエピソードで行動 a が異なっていた。エピソード 3 分割は、エピソードを分割したのにも関わらずすべての行動が同じになってしまっていることからエピソード全体で最適な渋滞考慮係数を選択していると考えられる。

また、エピソード 2 分割は行動 a が収束していないことから、学習が不完全であることが考えられる。

表　３．３．７－７　Path 基準向け最適化 AI 開発(エピソード 3 分割)　推定 100 回結果

1回目の行動	2回目の行動	3回目の行動	選択回数	平均操業時間
(100.0, 1.0, 50.0, 1.0)	(100.0, 1.0, 50.0, 1.0)	(100.0, 1.0, 50.0, 1.0)	100	407.8

３．４　実施項目③ロジックソルバの構築

３．４．１ 成果概要

ロジックソルバについて、データモデル基盤を中心とした観測情報マッピング、任務タスク管理、経路計画、交通制御の連携の基本設計を行った。AI フェイルセイフ設計として、ロジックソルバをベースとしたモデルベース強化学習に適用する検討を行った。

３．４．２ ロジックソルバ構成

OODA 群制御 AI モジュールのロジックソルバ(LG ソルバ)は、タスクソルバ、マップソルバ、及び中核となるトラフィックソルバのソフトウェアモジュールで構成される。図 ３．４．２－１に示すシステム構成図の赤枠で示す部分である。構成モジュールの機能概要を表 ３．４．２－１に示す。構成モジュールの要件定義・基本設計を本項第（２）～（４）項に示す。

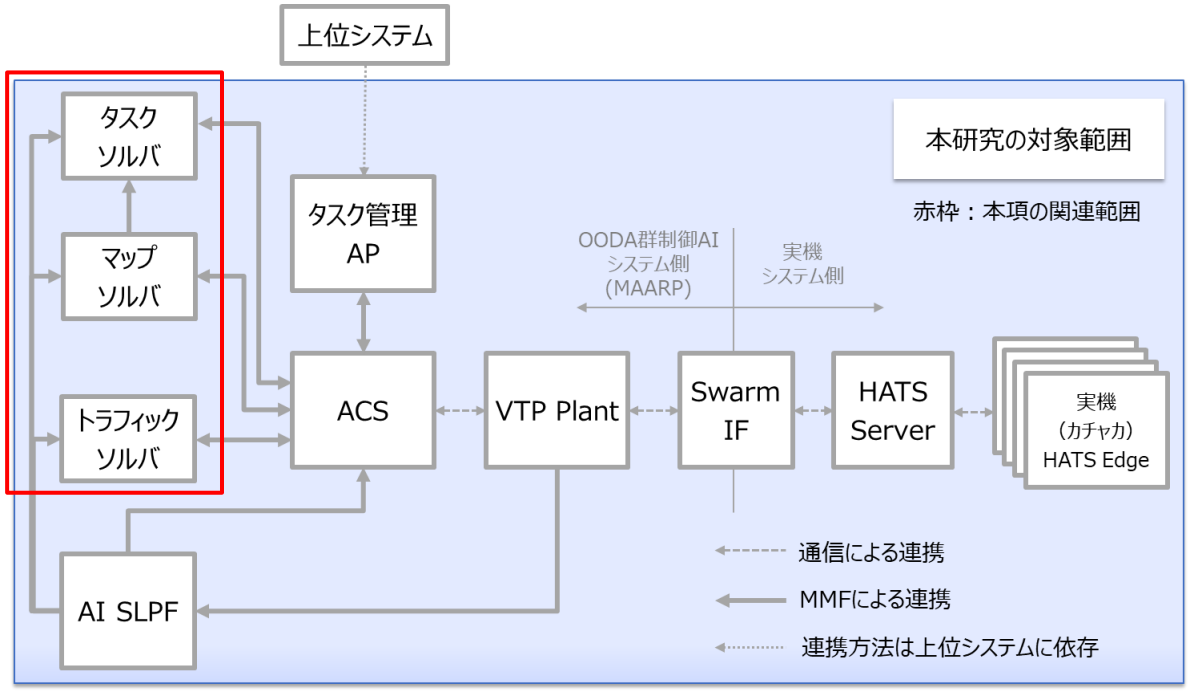

図 ３．４．２－１　システム概要図

表 ３．４．２－１　ロジックソルバの構成

対象	構成	担当機能
ロジックソルバ	トラフィックソルバ	経路生成、交通制御・空域管制、移動体の走行制御を担当するコアモジュールである。
	マップソルバ	AI 意思決定・群制御に必要な整理情報を、観測情報や応答情報から生成する。
	タスクソルバ	上位タスクに従い、担当エージェントや目的地を選定する。

３．４．３ トラフィックソルバ

３．４．３．１ 要件概要

トラフィックソルバは、対象エリアを俯瞰する中央の視点で、全体的な群制御を行うモジュールである。構成は、表 ３．４．３－１及び図 ３．４．３－１に示すように経路生成アルゴリズム、交通制御(空域管制)アルゴリズム、運動制御アルゴリズムが連動する構成である。

表 ３．４．３－１ トラフィックソルバの構成

対象	構成アルゴリズム	概要
トラフィックソルバ	配車管理アルゴリズム	目標担当選定アルゴリズムは、タスクで目的地種類や担当種類が指定されている場合、目的地位置と担当実体を選定する。トラフィックソルバに実装される。なお、タスクの生成は、タスクソルバが担当する。
	経路生成アルゴリズム	経路生成アルゴリズムは、選択した経路生成モードに従って、移動体が現在位置から目的地に到達可能な複数の経路(ルート)候補から、最適な経路(ルート)をひとつ選択する。
	交通制御(空域管制)アルゴリズム	交通制御は、移動体の存在可能空間の競合と衝突を回避する。所謂、ある機体が存在する可能性がある空間要素に他の機体が侵入できないように、コンマ秒レベルの周期的な排他制御を行っている。
	運動制御アルゴリズム	交通制御アルゴリズムに含まれ連動する。移動体 MB の加速・等速・減速をコントロールする。MB は、Path(経路節点リスト)と PMT(移動許可節点リスト)を受け取ると、PMT 節点リストの終端を目標節点として、各節点の制限速度を守るように走行し、目標節点で停止する。

(*1) **「配車管理」の概念整理**：「配車管理」は「配車計画」の機能の一部である。「配車計画」の機能は、「タスク生成」と「配車管理」で構成される。タスク生成は、ターゲット分布マップ(T-Map)からタスクを生成する。タスクの構成は、目的地(種類・地点)、担当(種類・実体)、任務タイプ、発行時間、到着予定時間等の情報である。タスクソルバに実装される。

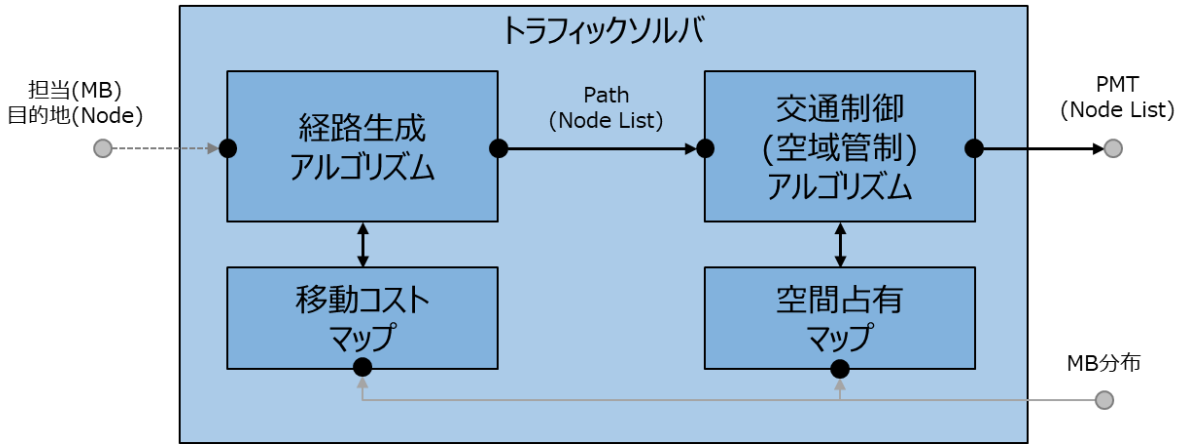

図 ３．４．３－１ トラフィックソルバ制御フロー

３．４．３．２ 経路生成アルゴリズム

（１） 概要

経路生成アルゴリズムは、選択した経路生成モードに従って、移動体の現在位置から目的地に到達可能な複数の経路(ルート)候補の中から、最適な経路(ルート)をひとつ選択する。現時点では、経路生成モードは、表 ３．４．３-２示すモードのうち時間優先のみ選択できる。

(1) 距離優先
(2) 時間優先（渋滞回避 On/Off）
(3) 省エネルギー優先

経路生成では、経路(ルート)候補について、探索モードに対応した表 ３．４．３-３に示す目的関数を計算し、目的関数が最小となる経路(ルート)をひとつ Path として選択する。目的関数は、AGV が現在位置から目的地に到達するまでの物理量を集計する。その物理量は、距離優先モードの場合は「走行距離」、時間優先モードの場合は「所要時間」、省エネルギー優先モードの場合は「所要エネルギー」となる。

表 ３．４．３-２ 経路生成モード一覧

モード	定義	備考
距離優先	AGV が現在位置から目的地まで走行するときの「走行距離」を目的関数とし、この値が最小となる経路を選択する。走行距離が同じ場合、旋回の回数が少ない方を選択する。	
時間優先	AGV 現在位置から目的地まで走行するときの「所要時間」を目的関数とし、この値が最小となる経路を選択する。渋滞は時間に影響するため、渋滞回避は本モードで考慮する。他のモードでは考慮しない。	実装済
省エネルギー優先	AGV が現在位置から目的まで走行するときの「所要エネルギー」を目的関数とし、この値が最小となる経路を選択する。(走行以外のアクションによるエネルギー消費は考慮しない。)	

表 ３．４．３-３ 目的関数の一覧

目的関数	目的関数の構成	備考
走行距離	直進走行距離と倣い走行距離の総和 → AGV が走行するライン要素(タグエッジ長)の総和となる。	距離優先モード
所要時間	以下の値の総和 直進走行時間　＝　直進走行距離/最大速度 倣い走行時間　＝　倣い走行距離/倣い速度 旋回時間　＝　旋回所要時間 x 旋回回数 渋滞時間増　＝　閾値を越えた経路上の AGV 台数に比例して時間を追加	時間優先モード
所要エネルギー	以下の値の総和 直進走行抵抗力に抗する仕事＝走行距離に比例、抵抗係数と自重に比例 倣い走行抵抗力に抗する仕事＝走行距離に比例、抵抗係数と自重に比例 加速による運動エネルギー＝加速回数に比例、一時停止によるものは含まない。 旋回による運動エネルギー＝旋回回数に比例	省エネルギー優先モード

また経路生成アルゴリズムは、表 ３．４．３-４に示す渋滞回避機能を備える。渋滞回避の詳細は次項に示す。

上記経路生成が行われるタイミングとしては、任務タスクが発行されたときに加え、以下の２つの想定外の事象が発生したときにも行われる。

(a) 移動体が走行中に関連するタスクの RCT 情報が更新されたとき
(b) 移動体に中度異常障害が発生したとき

上記(a) については「E) 未知要素対応 RCT 情報マップ連接」にて、(b) については「F) 故障対応」にて詳しく示している。

表 ３．４．３-４ 渋滞回避モードの概要

項目	内容	備考
On/Off	UI または入力ファイルで、渋滞考慮の有効化・無効化を設定する。 渋滞考慮は、経路生成モードが「時間優先」の場合のみ対応する。	
判断タイミング	対象 AGV が、目的地(FromTo)を受け取ったときに、経路生成を行います。 ＊走行中の渋滞考慮は行いません(将来対応可能)。処理時間が増え、多台数対応性能に悪影響となります。	

（２） 流体物流理論による過密化低減・渋滞回避

現状、渋滞の検知は移動予定経路上の移動体の密度で判断を行っている。そのため近隣ノードで渋滞が発生していた場合にはそれを検知できず、走行中に渋滞が広がってしまいパス生成時には存在しなかった想定外の渋滞に巻き込まれてしまうといった現象が発生することになる。

より高度な渋滞の検知を行うには近隣ノードの移動体の密度も考慮する必要がある。ノードグループおよびライングループを含むある一定の大きさで区切られたエリアという概念(CAREA)を導入し、エリアごとにその中に含まれる移動体数とライン長から移動体密度を導き出し、重み係数をかけた形で渋滞時間増加量の計算を行い、それをコストとすることで広域に渋滞の検知を実現させる。

この基本となる理論が流体物流理論である。流体物流理論は、流体と移動体集合の類似性に着目した、交通整流化・渋滞回避の理論である。流体は流路や貯留槽の許容流量を超えると流れが阻害される。これを表 ３．４．３-５に示すように移動体の経路計画や交通制御に応用した。パス基準は、エージェントが目的地を受け取ったときに、経路候補上の他のエージェントの数量に比例するコストである。エリア基準は、エリア内の節点やライン上に居るエージェントの数量に比例するコストである。本研究で実装する。なお、基準とする指標は、移動体に変えて、Pathとする場合もある。

AIや最適化により、これらの重みをコントロールすることを想定している。

表 ３．４．３-５ 流体物流理論による過密化低減・渋滞回避手法

手法	パス基準	エリア基準
イメージ	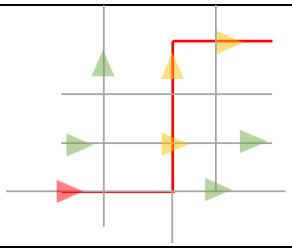	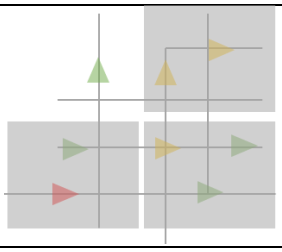
付加 コスト	Wf ＊ f(Density) Density = Path 上の他の移動体の密度 Path 上の他の Path 節点の密度	Wf x g(Density) Density = 指定エリア内の移動体の密度 指定エリア内の Path 節点の密度

（３） 開ループ・ノード間双方向対応

開ループ(行き止まりノードがある)とノード間の双方向が可能となるマップ(図 ３．４．３-２参照)をサポートする。また、行き止まりのノードについては、主に移動体の入場・退場地点としての利用を想定する。

ノード間の双方向移動については、ノード間に逆向きの２つの単方向ラインを設定することを想定する。よってマップを構成するためのデータモデルは既存のまま利用可能であるのだが、経路の探索を行う際に無限にループして探索しつづけることのないようにしなければならない。

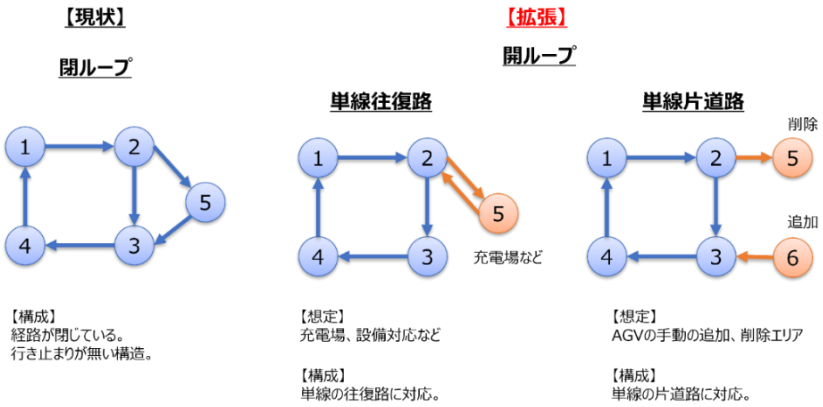

図 ３．４．３-２ 開ループのイメージ

（４） 未知要素対応 RCT 情報マップ連接

RCT 情報マップとトラフィックソルバの関係を説明する。RCT 情報マップは、配下エージェントの観測情報及びマップソルバの整理情報を、AI や群制御の判断材料として適した構造のマップモデルにプロットしたものである。トラフィックソルバの経路生成や交通制御は、これらのマップ情報に連接した移動コストマップや空間占有マップの情報を用いて制御演算を行う。

RCT 情報マップの運用について説明する。移動体に搭載された各種センサによって、管理外の未知の物体が検知された場合の処理を想定する。具体的には、図 ３．４．３-３に示すように、検知された物体を脅威、障害物、目標のいずれかに分類して管理することで、管理化にある移動体の動きを制御することを目的としている。RCT 考慮とは、Risk、Cost、Target のことであり、それぞれ脅威、障害物、目標を表す。Risk および Cost とみなされるとそれを避けるように、Target とみなされるとそれを目指すように動かす。移動体が行っているタスクごとに未知物体に対する振る舞いは異なり、例えば救助中のロボットからみたときに Risk であるものは、捕獲中のロボットからみたときは Target でもある。このように移動体が行っているタスクの種類ごとにコストや目的地の情報を動的にアップデートしながら管理化にある移動体の制御（主に経路生成）を行うものとする。

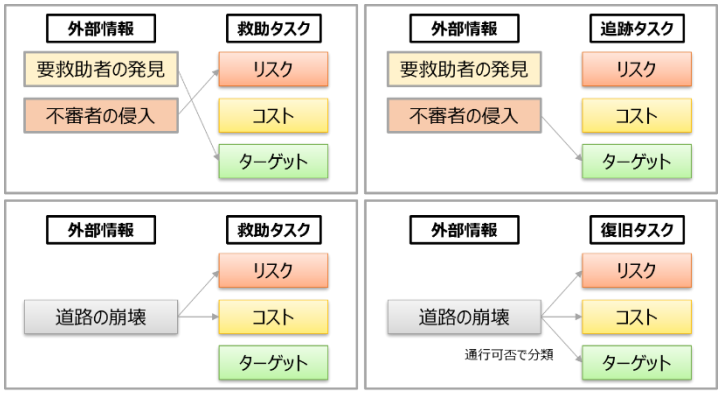

図 ３．４．３-３ RCT 分類例イメージ図

３．４．３．３ 交通制御(空域管制)アルゴリズム

（１） 概要

交通制御は、移動体の存在可能空間の競合と衝突を回避する。所謂、ある機体が存在する可能性がある空間要素に他の機体が侵入できないように、コンマ秒レベルの周期的な排他制御を行っている。交通制御アルゴリズムは、表 ３．４．３－６に示すように運動制御と衝突回避の制御演算を行っている。それぞれの詳細は後述する。

表 ３．４．３－６ 交通制御 構成機能解説

機能	概要
運動制御	移動体 MB の加速・等速・減速をコントロールします。MB は、Path(経路節点リスト)と PMT(移動許可節点リスト)を受け取ると、PMT 節点リストの終端を目標節点として、各節点の制限速度を守るように走行し、目標節点で停止します。なお、MB は、走行中に PMT を累積することができます。PMT が累積されると、目標節点も累積された PMT リストの終端に変更されます。
衝突回避制御	遅延許容・シミュレーション予測制御により、PMT を生成し、衝突を回避している。 MB は、数秒から数十秒先の少し未来の行動範囲(走行予定空間サーチ範囲)の空間(ここでは節点)の占有状態を探索しながら、走行する。IS MB の探索時に、空間(節点)が占有されていない場合は、節点を占有し、走行を継続する。空間(節点)が占有されている場合は、その手前の節点で停止するように、減速する。空間の占有状態は、占有マップで一元的に管理される。

（２） 指定エリア制限制御

指定エリア制限制御は、交通制御アルゴリズムの構成要素である。指定エリア制限制御の機能は、図 ３．４．３－４に示すように、指定したエリア内の MB 台数が上限値以下になるように、エリアへの MB の流入を管理する。管理は占有マップを利用し、エリア入口の節点占有のオン・オフにて行う。エリアからの MB の流出は自由である。本機能で想定するユースケースを表 ３．４．３－７にまとめる。関連する図を、図 ３．４．３－５～に示す。

指定エリアの考え方を経路生成アルゴリズムに応用することで、エリア内の過密度を考慮した経路生成を行うことができる。

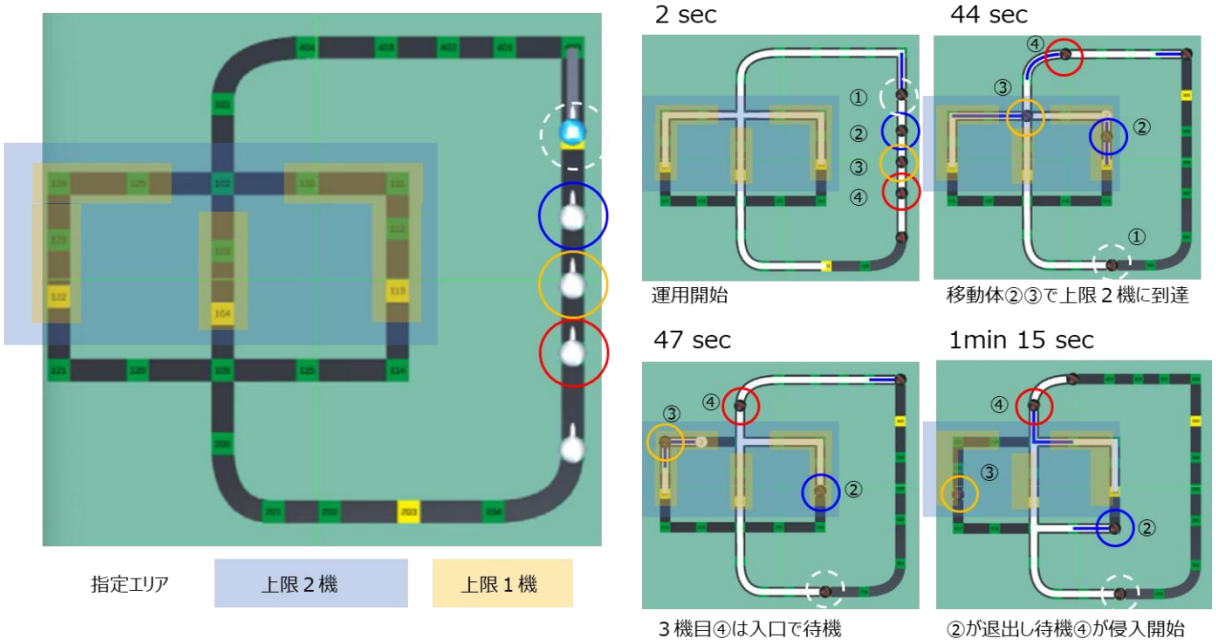

図 ３．４．３－４ 交通制御アルゴリズム 指定エリア機数制限機能の概要

表　３．４．３－７　指定エリア制限制御の用途(ユースケース)

No.	用途	内容
1	物理的干渉の回避	他の移動体との物理的な接触回避に用いる。磁気テープやタグ敷設の作業では、他の移動体との物理的な干渉を考慮していない場合がある。他の移動体との物理的な接触の恐れがあるエリアは、制限台数を１台とする。
2	優先通路	制限台数を１台とすることで、他の移動体の干渉を受けません。
3	往復用通路	充電などの非定常作業場所は、メインの経路から分岐した往復経路の先にある場合がある。先に進入した移動体の入退場の邪魔にならないように、他の移動体は手前で待機する必要がある。

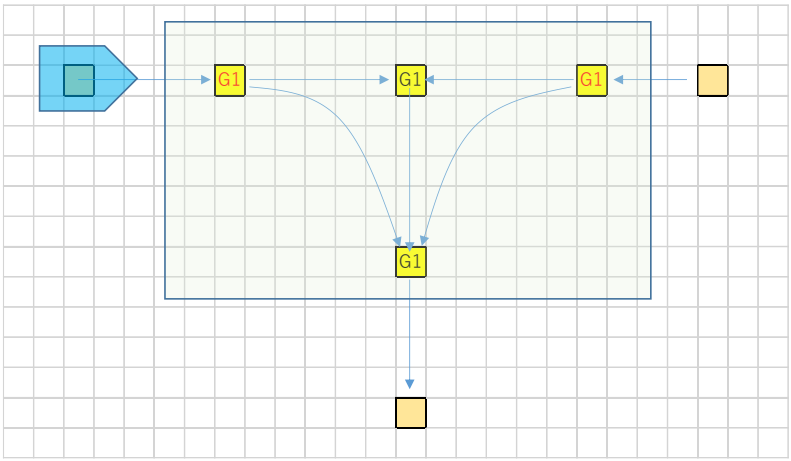

図　３．４．３－５　指定エリアの例：他の移動体と物理的に干渉する経路パターン

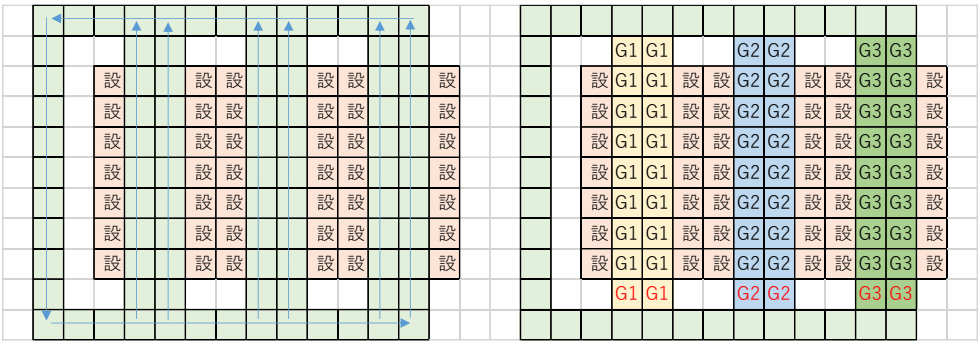

図　３．４．３－６　指定エリアの例：同時侵入台数が制限される作業エリア

指定エリア ID：G1、G2、G3　（節点 ID で指定）

３．４．３．４ 移動体モデル

（１） 種類

移動体の種類と動作を下表に示す。実用シナリオに対応する機種から実装する。

表 ３．４．３－８ 移動体種類一覧

No.	記号	名称	概要
1	MB	基本移動体	地上無人機のうちライントレース型・グリッド型 AGV を想定。 節点動作予測制御に準拠。
2	MBST	操舵方式 UGV	地上無人機のうち操舵方式で、旋回が出来ない型式のものを想定。 その他動作は MB と同じ。
3	MBRW	回転翼型 UAV	マルチコプターを想定。ホバリングが出来るため、動作は MB に準じる。 差異は Path 終末の節点停止はホバリング状態。
4	MBFW	固定翼型 UAV	固定翼機を想定。Path 終末や PMT 終末は、減速停止せず、終末 Node を中心に旋回することを想定する。なお、GUI の表現は、ACS、LG ソルバは終末 Node 上で停止・点滅、VTP Plant 3D 版は旋回運動を再現する。
5	MBDOG	犬型移動体	MB に準じる。

備考）*1 節点動作予測制御は、節点の制限速度順守や節点停止するように、事前に減速動作する移動制御のこと。*2 節点トリガー制御は、節点通過時に、制限速度順守や停止するように減速を開始する移動制御のこと。 *3 GUI 上の移動体の動作表現は、ACS・LG ソルバは抽象度が高くても良い。VTP Plant 3D 版は、動作を再現する。

（２） 運動動作

表 ３．４．３－９ 移動体動作一覧

No.	移動体動作	概要
1	前進(直進)	方向を変えずに前方に進む。
2	前進倣い ・操舵旋回	前進しながら回転運動を行う。 「操舵旋回」は前進倣いに相当するが、固定翼機について用いる。
3	旋回(ピボット)	移動体の速度がゼロの時の回転運動を指す。なお、固定翼機で使う「旋回」は、操舵旋回を意味する。前進しながら回転運動を行う。前進倣いに相当する。
4	停止 ・ホバリング ・待ち旋回	トラフィックソルバの Path や PMT の端末節点上に停止する。あるいは節点トリガー制御では停止動作にはいる。ホバリングは回転翼無人機に用いる。 待ち旋回は固定翼無人機に用いる。停止点を中心に操舵旋回する。
5	目的地作業	移動体が目的地でおこなう作業のこと。作業所要時間としてモデル化する。充電も目的地作業に含まれている。
6	後進(直進)	機首と反対方向に進むこと。
7	後進倣い	機首と反対方向に、ステアリングを切りながら進むこと。
8	緊急停止	異常系への対応として走行中の移動体になんらかのトラブルが発生して緊急停止してしまう場合を扱う。正常系においては、目的地到達、占有解除待ち、旋回直前とすべてノード上での停止のみだったが、緊急停止においてはノード間走行中の状態からの停止も扱うことになる。またノード上であっても旋回中の停止も起こり得る。
9	上昇・下降	無人航空機に用いる。前進しながら、あるいはホバリング状態で、上昇・下降する。
10	離陸・着陸	無人航空機に用いる。
11	地上走行	固定翼無人航空機に用いる。離陸前、滑走路での離陸・着陸時、着陸後に停止位置への移動が想定される。

表 ３．４．３−１０　移動体動作一覧

No.	移動体動作	MB 基本移動体	MBST 操舵移動体	MBRW 回転翼機	MBFW 固定翼機	MBDOG ロボット犬
1	前進(直進)	○	○	○	○	○
2	前進倣い	○	○	○	操舵旋回	○
3	旋回(ピボット)	○	—	○	—	○
4	停止	○	○	ホバリング	待ち旋回	○
5	目的地作業	○	○	移動しながら	移動しながら	○
6	後進(直進)	○	○	○	—	○
7	後進倣い	○	○	○	—	○
8	緊急停止	○	○	○	○	○
9	上昇・下降	—	—	○	○	—
10	離陸・着陸	—	—	○	○	—
11	地上走行	—	—	○	○	—

（３）　制御方式

ロジックソルバが対応する移動体の種類、及び制御方式を示す。なお、現時点では、MBと減速タイミング予測制御に対応している。

表 ３．４．３−１１　移動体の種類

移動体名称	記号	制御方式	サポートする運動動作
地上無人機 (AGV)	MB (AGVC)	タイミング予測制御	前進、前進倣い、旋回後前進*1、 後進、後進倣い、旋回後後進*1、 停止＆作業、停止＆充電
地上無人機 (AMR)	MBA	タイミング予測制御	
無人航空機 マルチロータ型	MBMR	タイミング予測制御	前進、操舵旋回*1、ホバリング、旋回後前進*1、前進上昇、前進下降、ホバリング上昇、ホバリング下降、着陸停止
無人航空機 固定翼型	MBFW	タイミング予測制御	前進、操舵旋回*1、待ち旋回*2、前進上昇、前進下降、着陸停止

備考）*1 一般的に、機体の向きを変える動作を旋回というが、無人機の種類で挙動が異なる。地上無人機及びホバリングできる無人航空機において、旋回は速度ゼロ、その場で機体の向きを変える動作をいう。固定翼無人航空機の旋回は、前進しながら機体の向きを変える動作となるため、ここでは操舵旋回という。地上無人機の前進倣いに相当。 *2 待ち旋回は、停止ノードを中心に一定の半径の円周上を飛行する動作をいう。

表 ３．４．３−１２　制御方式の種類

制御方式	内容
タイミング 予測制御	通過点のノードの制限速度を守るため、または目的地のノード上に停止するために、現在の速度に応じて通過点や目的地の手前から適切なタイミングで減速を開始する制御のこと。 図 ３．４．３−７参照
節点トリガー制御	通過点や目的地として指定されたノードに到達した時に、ノードに設定された制限速度や停止等の条件を守るように動作を開始する制御のこと。 図 ３．４．３−８参照
節点誘導制御	節点を通過するように無人機を誘導する制御のこと。経路として節点リストで定義される場合や、操縦者が節点を移動して誘導する場合がある。ウェイポイント制御のこと。

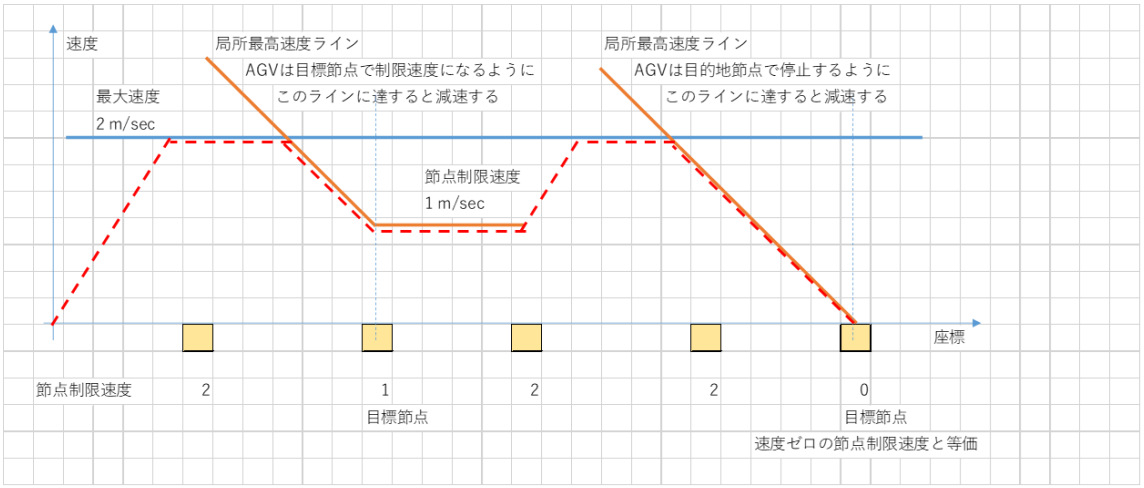

図　３．４．３－７　減速タイミング予測制御のイメージ

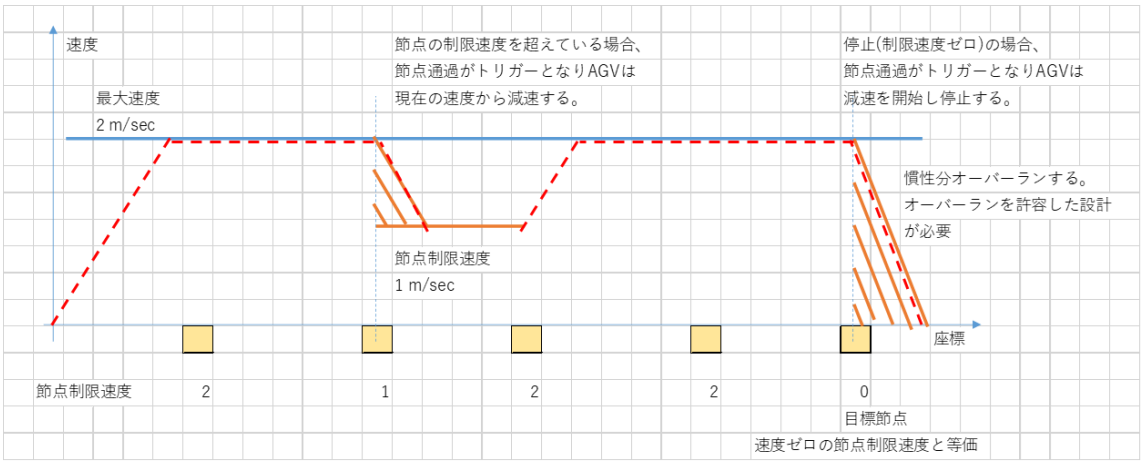

図　３．４．３－８　節点トリガー制御のイメージ

（４） 故障レベル

故障発生時の制御フローを示す。移動体に故障が発生すると、まずは故障発生という状態がACSから通知される。この状態ではまだ故障レベルが不明なため 緊急停止の処理のみを行い待機することになる。何が起きたのかが判明し故障レベルが確定されると改めてACSから故障判断が通知される。

故障レベルについて説明する。故障レベルには重度、中度、軽度の３つがあり、それぞれの状態に応じて故障判断(重度)、故障判断(中度)、故障判断(軽度)が通知され、適切な処理が求められることになる。

故障への対処について説明する。重度の場合には移動体の撤去が必要となり、中度、軽度の場合には復旧処理が必要となる。なお、撤去された移動体であっても、その後修理が行われて改めてマップ上に再配置される可能性もあることに注意が必要である。

表 ３．４．３－１３　ACS から送られてくる故障時関連の通知と挙動

No	通知	挙動
1	故障発生	急停止して、その場で待機する。 旋回中、作業中、充電中の場合も、それぞれの処理を中断する。
2	故障判断（重度）	復旧不可のため、シミュレーション上から削除する（強制撤去）。
3	故障判断（中度）	PATH、PMT をクリアし、その場での待機を継続する。 充電中、作業中の場合は、それぞれの処理を終了したものとして扱う。
4	故障判断（軽度）	PATH、PMT を保持したまま、その場での待機を継続する。 旋回中、充電中、作業中の場合は、それぞれの処理を中断させる。
5	復旧	「故障判断（中度）」の場合、アイドル状態となり、次のタスクの受信待ちとなる。 「故障判断（軽度）」の場合、その場から走行を再開する。旋回中、充電中、作業中の場合は、それぞれ中断した残りの処理を継続する。
6	撤去	管理上から削除する。
7	再配置	管理対象として新しく移動体の追加を行う。

表 ３．４．３－１４故障発生時の対応早見表

No	故障判断	PATH	PMT	発生直後の状態	復旧
1	**重度**	クリア	クリア	シミュレーション上から削除する。(強制撤去)	（再配置する）
2	**中度**	クリア	クリア	その場での待機を継続する。 充電中、作業中の場合は、それぞれの処理を終了したものとして扱う。	アイドル状態となり、次のタスクの受信待ちとなる。
3	**軽度**	保持	保持	その場での待機を継続する。 旋回中、充電中、作業中の場合は、それぞれの処理を中断させる。	その場から走行を再開する。 旋回中、充電中、作業中の場合は、それぞれ中断した残りの処理を継続する。

（５） 実機移動体への要求

制御対象となる移動体は、安全性と性能の観点から、前述の交通制御の仕組みに適合している必要がある。その内容を、表 ３．４．３－１５及び表 ３．４．３－１６に示す。

表 ３．４．３－１５ ステータス通信とタイミング（ACS-移動体間の通信）

項目	概要
要求	移動体は、ステータス情報を、随時または周期的に、制御側の ACS へ送信できること。
背景	交通制御の占有マップにおいて占有解除に必要。ステータス送信のタイミングは、随時や短周期の方が、搬送性能にプラスとなる。デメリットは、AGV 台数が増える場合は、通信トラフィックに悪影響を与える場合がある。
備考	安全性、性能に影響

表 ３．４．３－１６ PMT 累積機能（ACS-移動体間の通信部）

項目	概要
要求	移動体は、通信機能として、移動許可コマンド(PMT)を累積できること。
背景	累積することで一時停止の回数を減らす。経路占有を最小限に留め、他の AGV の一時停止の回数を減らす。搬送時間の短縮・搬送回数の増加が期待できます。
備考	性能に影響

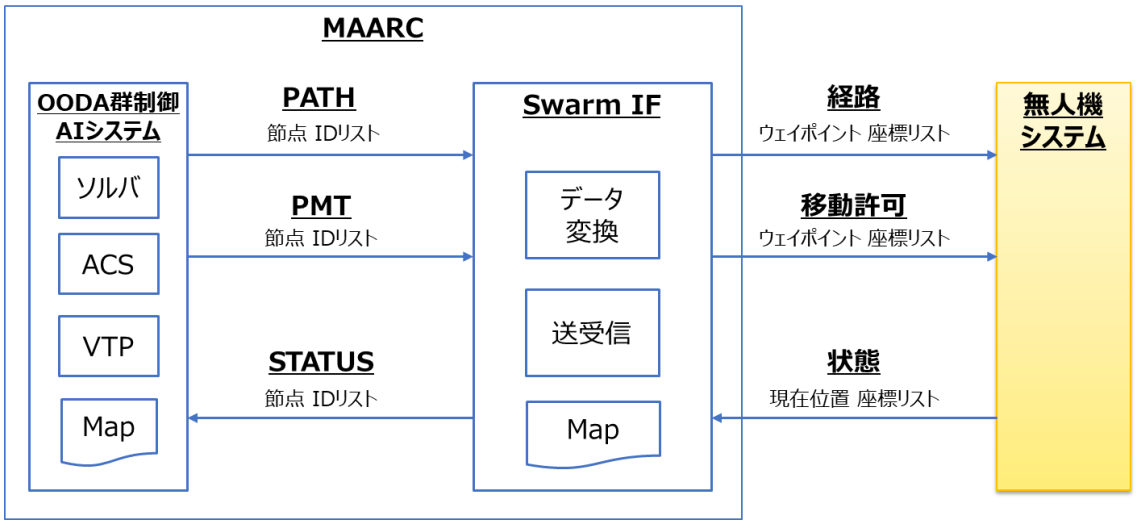

図 ３．４．３－９ MAARC・無人機システム間インターフェースの概要

３．４．３．５ 安全性設計事項

交通制御アルゴリズムの安全性について、表 ３．４．３－１７に示すように、論理、運用設計、及び運用誤差の観点で考慮する必要がある。

OODA群制御AIシステムにおいて、考慮すべき安全設計項目を表 ３．４．３－１８～に示す。

表 ３．４．３－１７　安全性の分類と概要

No.	分類	概要
1	論理安全性	交通制御の走行制御・衝突回避制御のロジックが、論理的に安全であることを示す必要がある。 ――― 例 ・ 応答遅延に対応した遅延許容制御ロジックが該当します。
2	運用設計安全性	移動体が走行時にトレースする磁気テープ(ライン)の配置やタグ(節点)の設置位置が、設計上、安全であることを示す必要があります。 ――― 例： ・ 設計では、AGV 運用シナリオで想定される搬送パターンについて、対象 AGV が他の AGV と物理的に干渉しないように磁気テープやタグの配置を決める必要がある。 ・ 倣い曲線部について、走行制御のライン走行長さを、実測に近いベジエ曲線ではなく、節点間の直線を用いることで、論理安全性を保つ。
3	運用誤差安全性	設計と実地の誤差があっても、安全に運行できるように、論理安全性または設計安全性を確保する。 ――― 例： ・ ACS-AGV 間の応答遅延：応答遅延許容制御により、論理安全性を保っています。 ・ タグ設置位置の設計と施工の誤差：群制御ソルバは、位置決め誤差が数 mm オーダーで実績があります。これ以上の誤差については、検証が必要です。

表 ３．４．３－１８　論理安全設計項目

項目	条件概要
交通制御アルゴリズム	論理安全性を確保するためには、ソルバ内部の AGV の現在位置は、実機 AGV よりも先行している必要があります。また、AGV は、加減速制御について要求仕様を満足する必要があります。

表 ３．４．３－１９　運用安全設計項目

項目	条件概要
物理的な干渉	節点やラインの配置は、対象 AGV が他の AGV と物理的に干渉しないように、配置設計する必要があります。
節点トリガー制御	移動体の運動制御方式が節点トリガー制御の場合、UGV は目的地点のタグ位置からオーバーランして停止します。この場合、ズレがあっても他の UGV と干渉しないように、タグ配置を決める必要があります。また、固定翼 UAV の場合、PMT 端末節点または Path 端末節点において、定点旋回飛行する必要があります。
移動体特性考慮	固定翼 UAV の場合、PMT 端末節点または Path 端末節点において、定点旋回飛行する必要があります。

３．４．４ マップソルバ

３．４．４．１ 概要

マップソルバは、以下に示すように、観測情報の点群マップからRCT情報分析、ロジックソルバ用のネット構造マップに至る情報処理プロセスを担当する。RCT(Risk、Cost、Target)情報分析は、認知モデルの注意機能を参考にした。RCTモデル化・変動予測は計算力学の技術を応用する。

表 ３．４．４－１　マップソルバ機能一覧

No.	機能	概要
1	観測・FB情報 マッピング	Ob/FB情報マッピング。未知要素は、センシングにより検知され、点データとしてモデル化される。
2	RCT情報 マッピング	異種マップ間データ連携。状況認識用に、未知要素の点データは、RCT(Risk、Cost、Target)に分類され、メッシュ構造のマップにプロットされる。
3	RCT変化予測	情報は時系列で取得し、RCT分布の時系列データから、将来のRCT分布を予測する。AIの状態sとして利用可能。
4	マップ間データ連携	マップ構造が異なるマップ間のデータを、計算力学の手法を応用して変換する。
5	移動コスト変換 マッピング	経路計画アルゴリズムと判断用データ生成を行う。

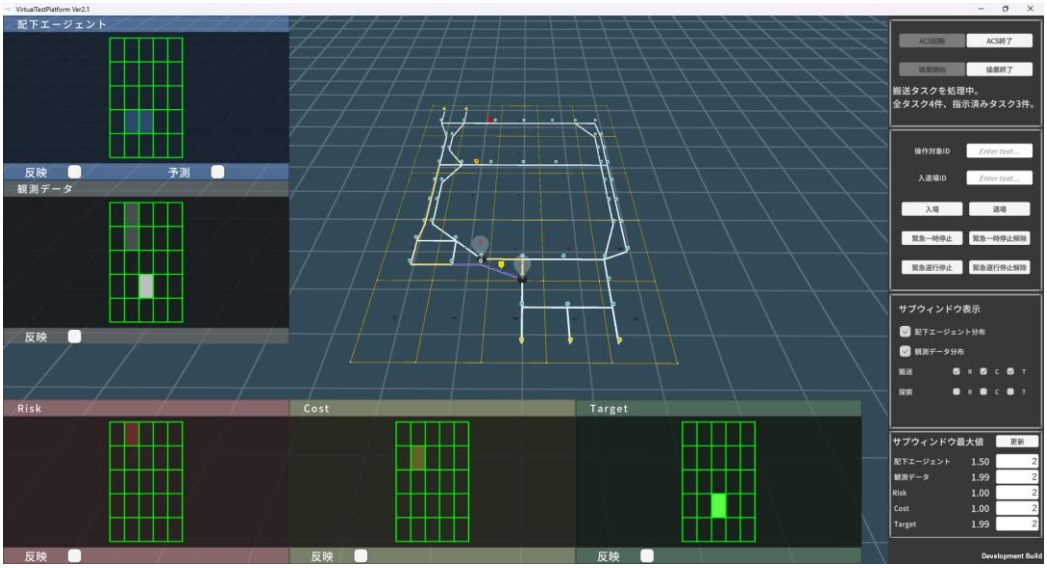

図 ３．４．４－１　配下エージェント密度、オブジェクト密度、RCT をメッシュマップに投影

３．４．４．２ マッピングアルゴリズム

（１） Ob/FB 情報マッピング

Ob情報とは、センシング情報のことである。移動体もしくは固定設備のセンサが検知したオブジェクトの情報をいう。フィードバック(FB)情報とは、配下エージェントが中央へ送信する自身の状態情報を言う。

これらの情報をベースに、図 ３．４．４－２に示すように、OODA機能アルゴリズムに必要な整理情報を適したマップモデルにプロットする。詳細は後述する。

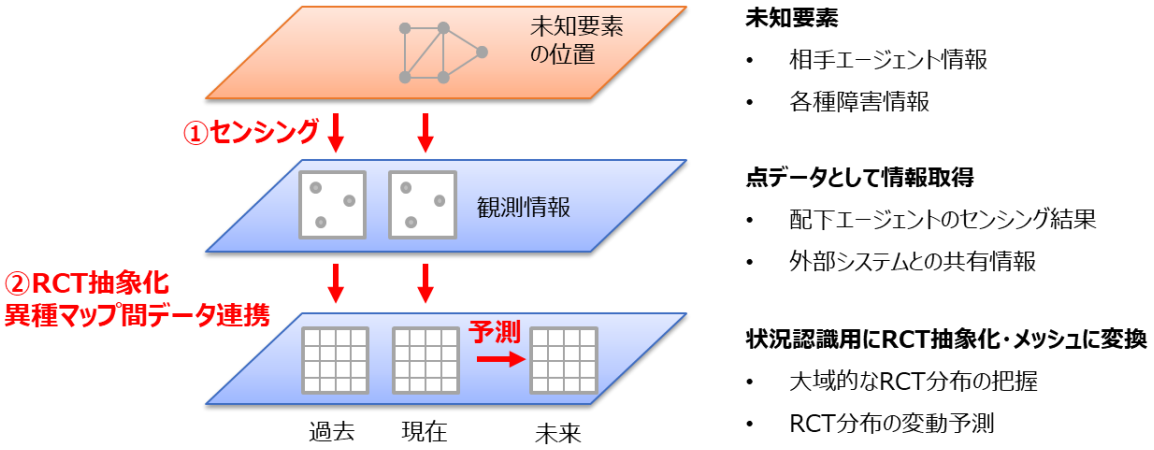

図 ３．４．４－２ 観測情報の取得からデータ分析・判断材料の生成イメージ

（２） RCT 情報マッピング

センシング情報は、リスク・コスト・ターゲットに分類され、各機能で使用される。リスクは回避すべき事象、コストは移動における非効率性、ターゲットは目的地の集合を示す。

同じ外部情報でも、図 ３．４．４－３に示すように、任務・タスクに応じてRCTが異なる。また、将来的にRCTの細分化にも拡張できるようにする。

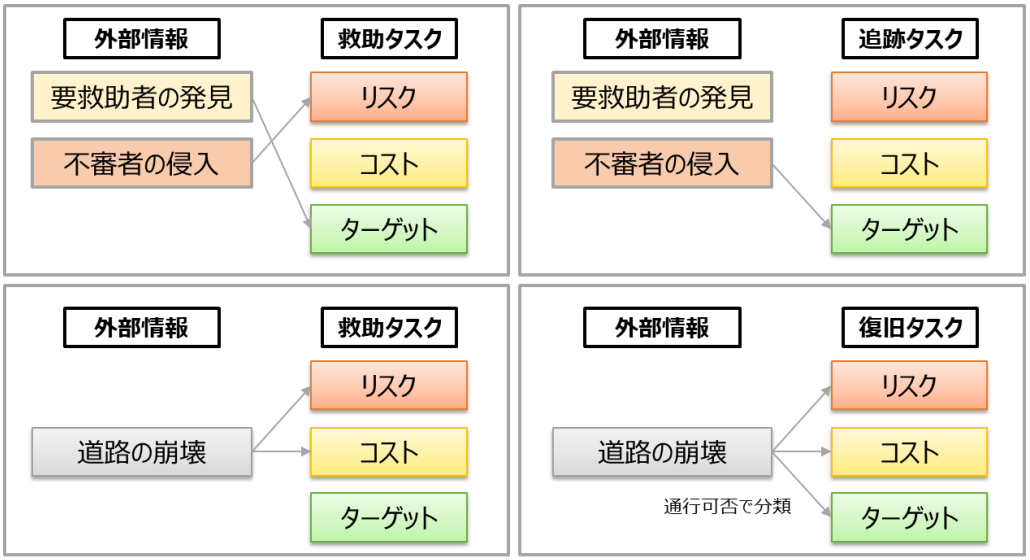

図 ３．４．４－３ 観測情報の抽象化・RCT 分析イメージ

（３） マップ間データ連携

異なる種類のマップ構造間のデータ連携の種類、データ配分の手法を、表 ３．４．４－２、図３．４．４－４、及び表 ３．４．４－３に示す。

表 ３．４．４－２ 異種マップ間データ連携のタイプ

No.	連携の種類	イメージ	概要
1	点群から メッシュ		観測情報の点群分布では、情報過多の場合。点群を分布として抽象化し、判断を支援する。
2	メッシュから ネット		LGソルバやAIソルバによる処理に用いる場合。
3	点群から ネット		LGソルバやAIソルバによる処理に用いる場合。

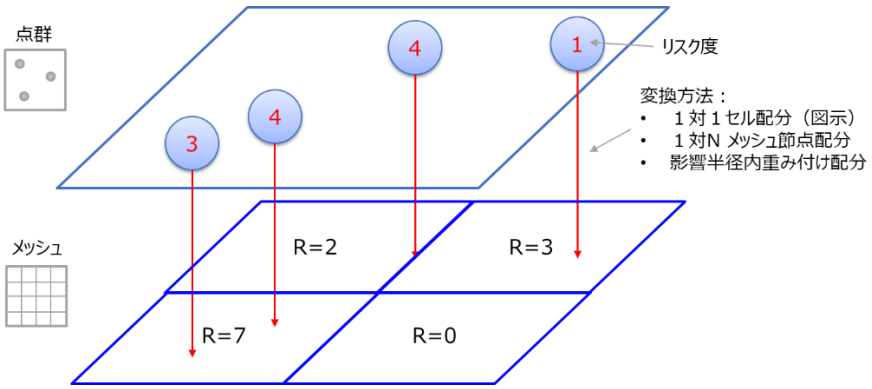

図　３．４．４－４　点情報のメッシュ構造マップへの配分方法イメージ

情報の影響範囲を踏まえ、データ変換を行う。変換方法は、計算力学の技術を応用する。複数の方法があるが、簡単なものから実装する。分布データは、セル中心で保持する方法(図示)とセル頂点で保持する方法がある。情報の特徴に応じて使い分ける。

表　３．４．４－３　メッシュ間データ配分方法

No.	区分	方法	概要
1	点・メッシュ変換	セル中心1:1配分	セル内に含まれる点情報を、セルに配分する。重心考慮場合に比べて計算量が低くなるが、重心位置が考慮されないため精度が落ちる。 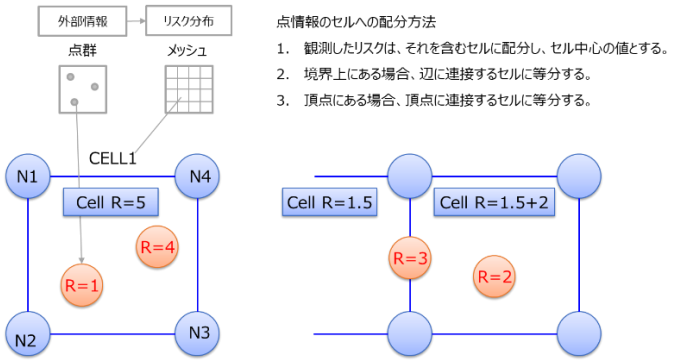
2	点・メッシュ変換	セル節点1:N配分	セル内に含まれる点情報を、セルを構成する節点に配分する。配分方法は、節点個数割り、重心考慮配分などがある。 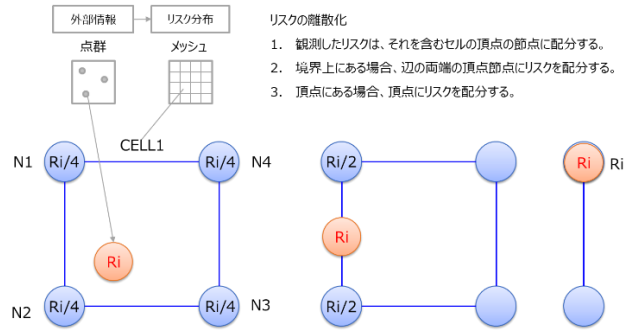
3	点・メッシュ変換	影響半径重み付け配分	計算力学の粒子法による離散化手法を応用する。影響半径内のセル中心または節点に、正規分布等を仮定して、重み付けをして配分する。 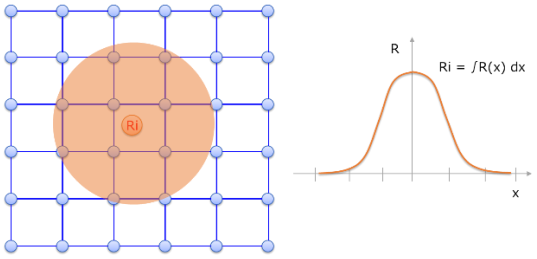

（４） RCT 変化予測（AI 状態 s 入力対応）

観測情報や整理情報の時系列マップを用いることで、表 ３．４．４－４に示すようにRCT分布の変動を予測できる。また、RCT変化予測マップは、図 ３．４．４－６に示すようにAIソルバの状態sの一つとして利用できるようにする。特に、時系列の間隔を長期・短期で出力できるようにする。

表 ３．４．４－４ RCT 変化の予測手法

No.	予測手法	概要	参照図
1	整理情報変化予測	観測情報をRCT変換し整理した情報の時系列マップから変化を予測する。	図 ３．４．４－５
2	観測情報変化予測	観測情報の時系列マップから変化を予測し、RCT情報に変換する。	図 ３．４．４－６

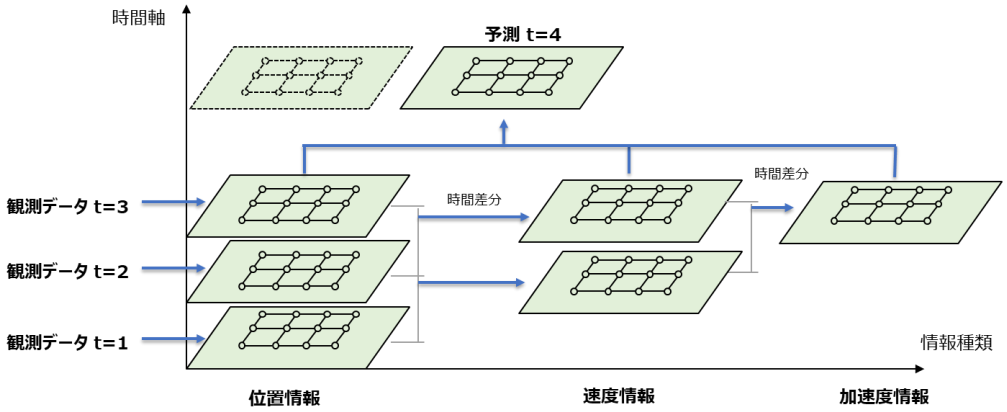

図 ３．４．４－５ 整理情報変動予測：RCT 分布変動予測イメージ

RCT 分布の予測は、計算力学の時間差分法・空間差分法を応用する。着目セルの隣接セル、及びそれらの時系列データから、着目セルの RCT 値(スカラー値、ベクトル値)を予測する。スカラー値はエージェント密度やポテンシャル等の度合いを示す。ベクトル値は方向を持つ風速などの度合いを示す。

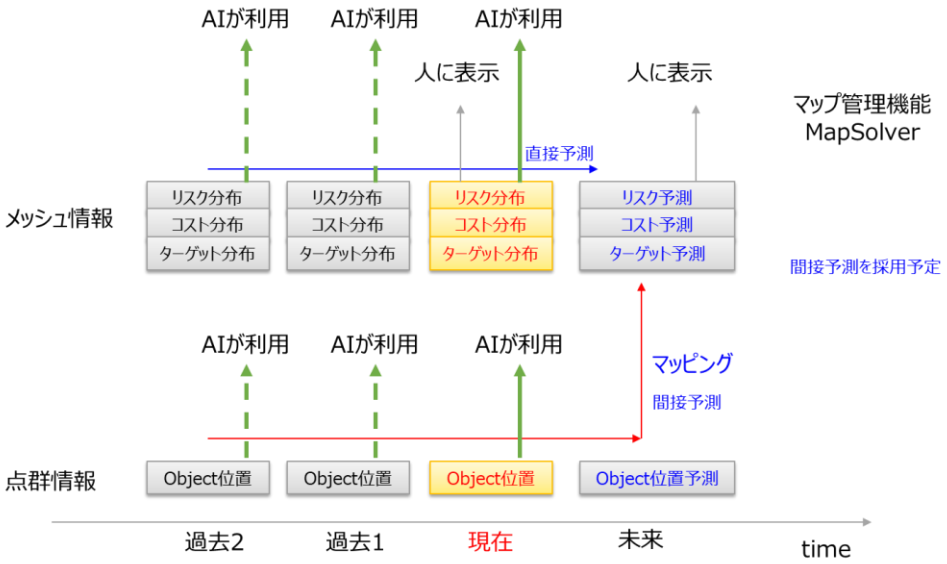

図 ３．４．４－６ 観測情報変動予測：点群情報変動予測・RCT 変換、AI 状態 s 入力イメージ

渡すのは現在の情報を渡す。過去のものは AI が保持して利用する。N 世代もちたい。N＝ 2 で進める。

３．４．５ タスクソルバ

タスクソルバは、移動体や目的地がグループ指定されたタスクを、最も効率の良い担当移動体と目的地を選定するためのモジュールである。タスク管理APで指定されるタスクは、移動体と目的地がセットされるが、それぞれ個々の移動体やノードを指定するだけでなく、同じ特性を持つ移動体や同じ特性を持つノードといった形でシステムに最適解を求めるような指定方法も提供されている。この最適解を導き出す処理を提供するのがタスクソルバである。

表 ３．４．５－１　タスクソルバ機能一覧

No.	機能	対応状況	概要
1	（単一エージェント）エージェントへのタスク割り当て	対応済	マップソルバから送られるTarget情報を用いて、空きエージェントにタスクを割り当てる。
2	タスクの再割り当て	対応済	失敗したタスクの再割り当てを試みる。
3	経路を妨げるエージェントの退避	対応済	エージェントの経路を妨げるエージェントがある場合、退避させる。
4	自動充電	対応済	充電率が低下したエージェントを充電場に向かわせる。
5	複数エージェントによるターゲットの追跡	未対応	複数エージェントに追跡タスクを割り当てる。
6	複数エージェントによるタスクの優先度判断	未対応	タスクの優先度を判断し、エージェントを何台割り当てるか判断。

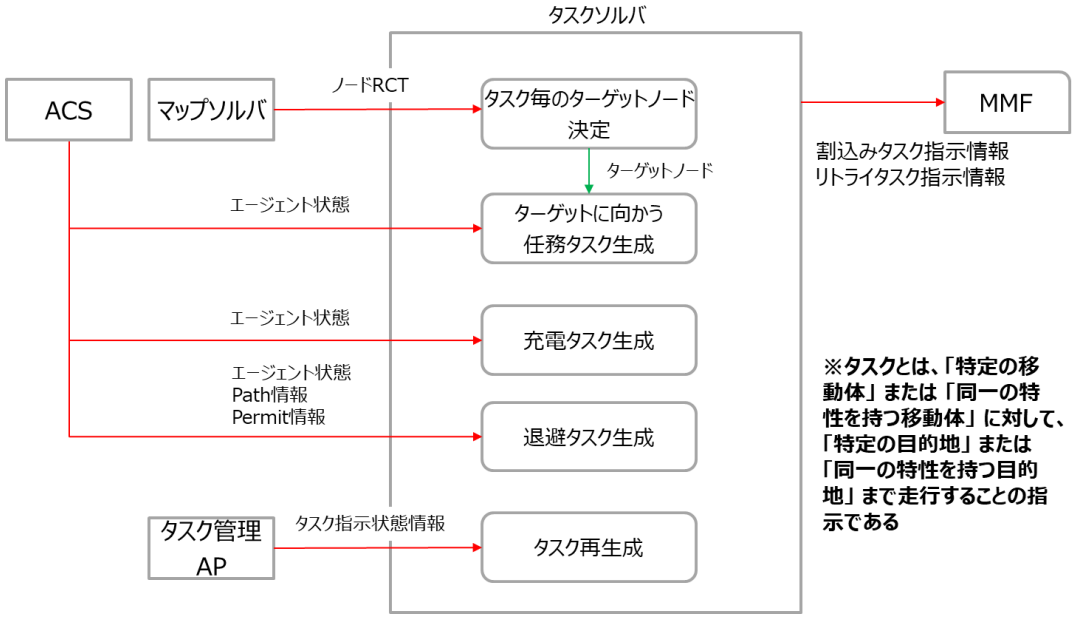

図 ３．４．５－１　タスクソルバの処理の内部処理フロー

３．５　実施項目④OODA群制御AIシステムの構築と試験実施

３．５．１ 成果概要

OODA群制御AIシステムは、ACS(エージェント制御システム)を中心に各アプリケーションやモジュールが連動する。本項では、OODA群制御AIシステムの司令塔となるACSについて報告する。

本研究では、実用シナリオ「工場倉庫の AGV 搬送」の各テーマに対して、ACS および連携する他システムとの IF の基本設計、実装を進めた（対応状況については以下の表、連携する他システムについては以下の図をそれぞれ参照）。

また、AI SLPF 向けに学習用、推論用の起動モードを実装し、自動学習環境の構築を進めた。

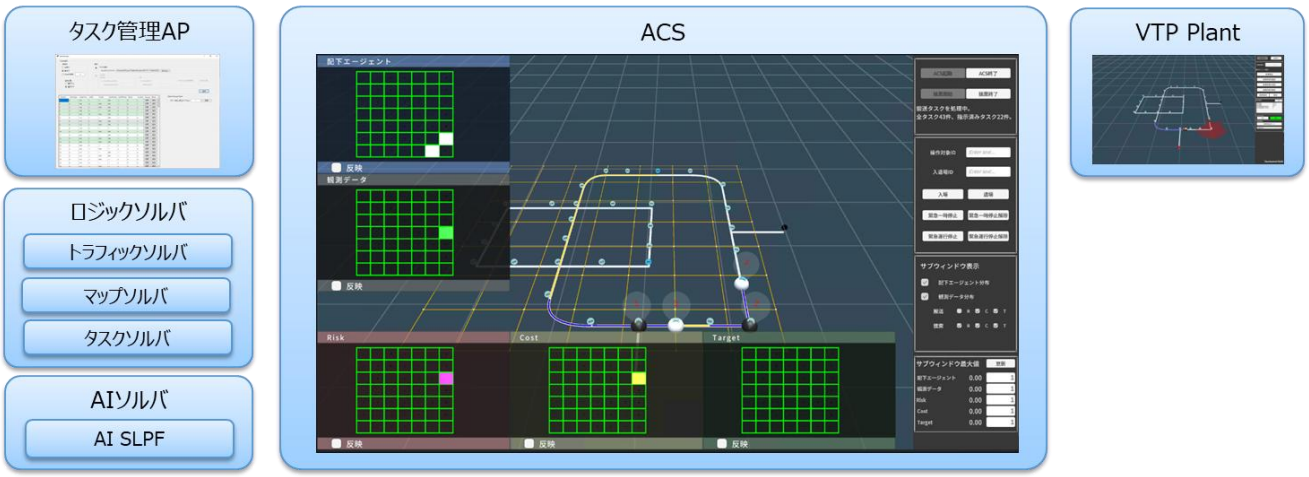

図　３．５．１－１ ACS と連携する他システム

表　３．５．１－１　ACS 対応状況

テーマ	主な対応内容	対応状況
交通全体最適	トラフィックソルバとの IF の改修、タスクの流量制御追加、タスク管理 AP によるタスク可視化	完了
突発事象対応	マップソルバとの IF 追加、緊急停止機能追加、入退場機能追加、サブウィンドウによるシミュレーション状況の可視化	完了
災害初動対応	タスクソルバとの IF 追加、UAV 対応のための GUI の 3D 化	連携確認中

３．５．２ システム概要

ODA 群制御 AI モジュールを搭載し配下エージェントを制御する ACS(エージェント制御システム)の基本設計を行った(図 ３．５．２－１参照)。ACS は制御コマンドを可視化する GUI を備える。AI ソルバの学習環境と ACS-VTP Plant-HATS 間の連携検討を行い、構成ソフトウェア間のデータフローを設計した。

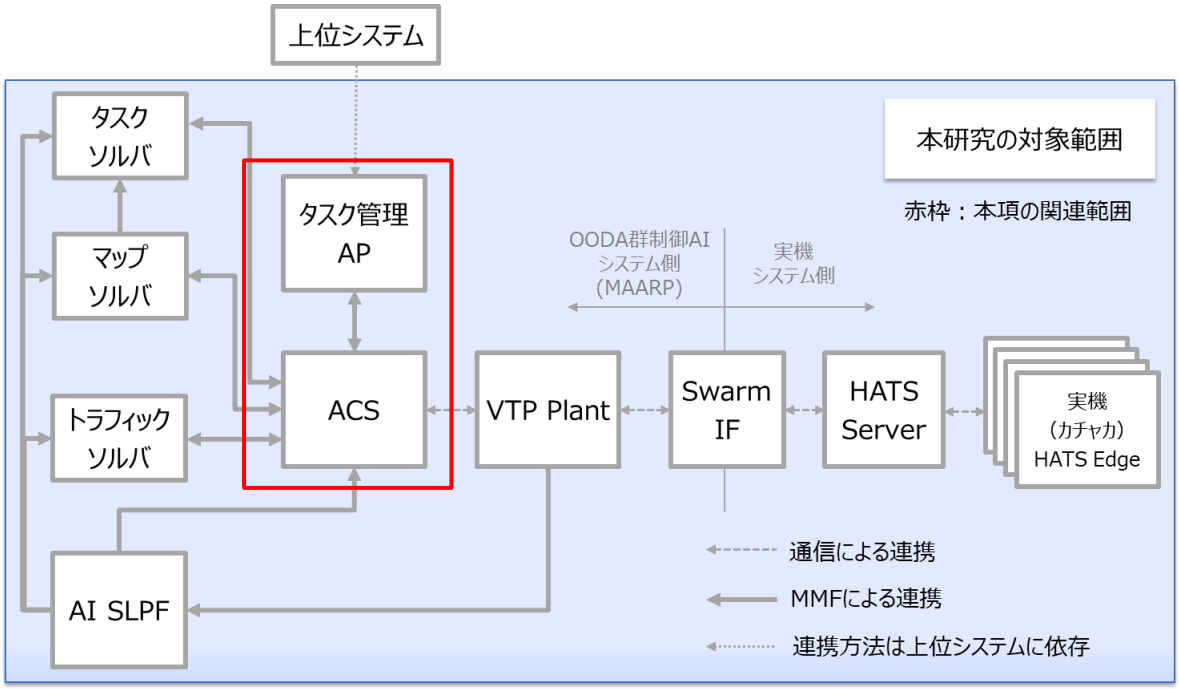

図 ３．５．２－１ システム概要図

３．５．３ タスクの制御

ACSは､タスク管理アプリケーション経由でMMFからタスク情報を取得し､タスクの割り当て、タスクの目的地までの経路情報およびPMTの作成をトラフィックソルバに依頼する。

（１） タスクの種類

タスクを定義するデータモデルとして、FromToとMoveTo（※）の2種類が存在する。通常はFromToタスクを使用し、マップ切替（詳細は「（8）マップ切替対応」参照）を利用する場合のみMoveToタスクを使用する。

（※）厳密にはMoveToSetとMoveToで構成

（ア）FromTo タスク

タスクは､「特定の移動体」 または 「同一の特性を持つ移動体」 に対して､「特定の目的地」 または 「同一の特性を持つ目的地」 まで走行することを指示する。「同一の特性」は、移動体はデータモデル「PMB」、目的地はデータモデル「PNODE」で定義する。

タスクの移動体と目的地の指定方法は以下の4パターンとなり、これらは混在することを許容する。

特定の移動体、特定の目的地が指定された場合を「個別指定」、同一の特性を持つ移動体、同一の特性を持つ目的地が指定された場合を「グループ指定」と呼ぶ。

表 ３．５．３-１ タスクの種類（移動体と目的地の組み合わせ）

移動体	目的地	備考
特定の移動体	特定の目的地	個別指定タスク
特定の移動体	同一の特性を持つ目的地	グループ指定タスク
同一の特性を持つ移動体	特定の目的地	グループ指定タスク
同一の特性を持つ移動体	同一の特性を持つ目的地	グループ指定タスク

（イ）MoveTo タスク

MoveTo タスクは、移動体、目的地の「個別指定」のみを設定でき、「特定の移動体」 に対して、任意の「特定の経由地」を経由して、「特定の目的地」まで走行することを指示する。また、目的地までの到達予測時間を使用して、目的地に同時に到着する（「同期行動」と呼ぶ）指定も可能である。

表 ３．５．３-２FromTo タスクと MoveTo タスクの比較

No	設定可能項目	FromTo タスク	MoveTo タスク
1	移動体・目的地の個別指定	○	○
2	移動体・目的地のグループ指定	○	×
3	経由地の指定	×	○
4	出発時間の指定	○	○
5	同期行動の指定	×	○

（２） タスクの最大値

「グループ指定」を含むタスクを処理する場合、最適な移動体や目的地の割り当てが必要となる。この処理には相応の処理時間を要するため、一度にトラフィックソルバに問い合わせができる件数の最大値（OrderMax）を設けることで、処理負荷の流量制御を実装した。

なお、移動体、目的地がともに個別指定の場合（従来のタスク）は、特に制限を設けない。

表 ３．５．３-３ タスクの流量制御の対象可否

移動体	目的地	流量制御の対象
特定の移動体	特定の目的地	×
特定の移動体	同一の特性を持つ目的地	○
同一の特性を持つ移動体	特定の目的地	○
同一の特性を持つ移動体	同一の特性を持つ目的地	○

３．５．４ UI

本機能の要件を以下に示す。

- メイン画面は、研究者が着目するエリアを拡大表示し、AI 上のエージェント位置、制御コマンドの可視化できること。
- ミニマップは、特徴量（エージェント密度分布、RCT 情報分布、地形特徴・等高線など）を表示できること。
- 操作は、システム開始・終了、任務開始・終了ができること。
- 非画像情報として、リソース、可能アクションなどが表示できること。
- エージェント情報は、選択中のエージェントの情報などが表示できること。
- 配車管理画面では、任務オーダーの管理、割込み操作ができること。

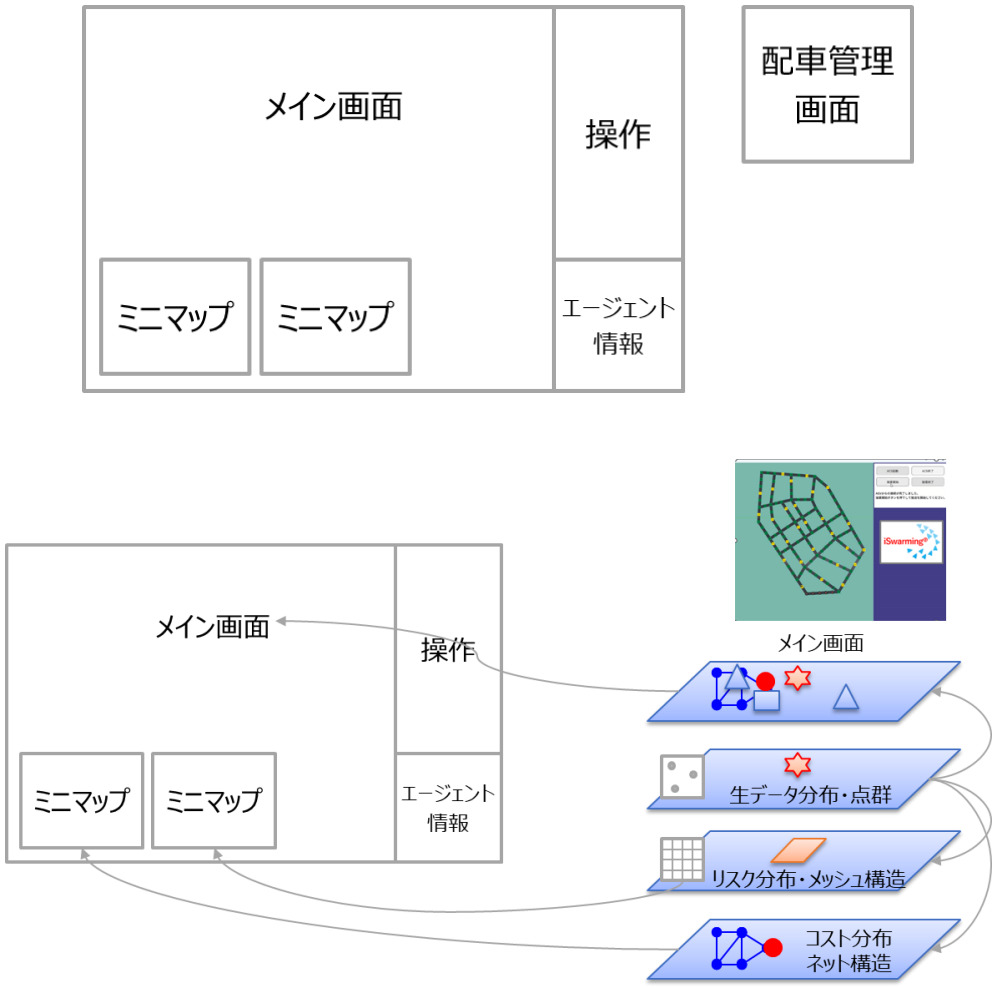

図　３．５．４－１　ACS の画面レイアウト構想

（１） 画面レイアウト

ACSの画面レイアウトは以下のとおり、7つの画面エリアから構成される。ACSの各画面エリアについては以下のとおり。

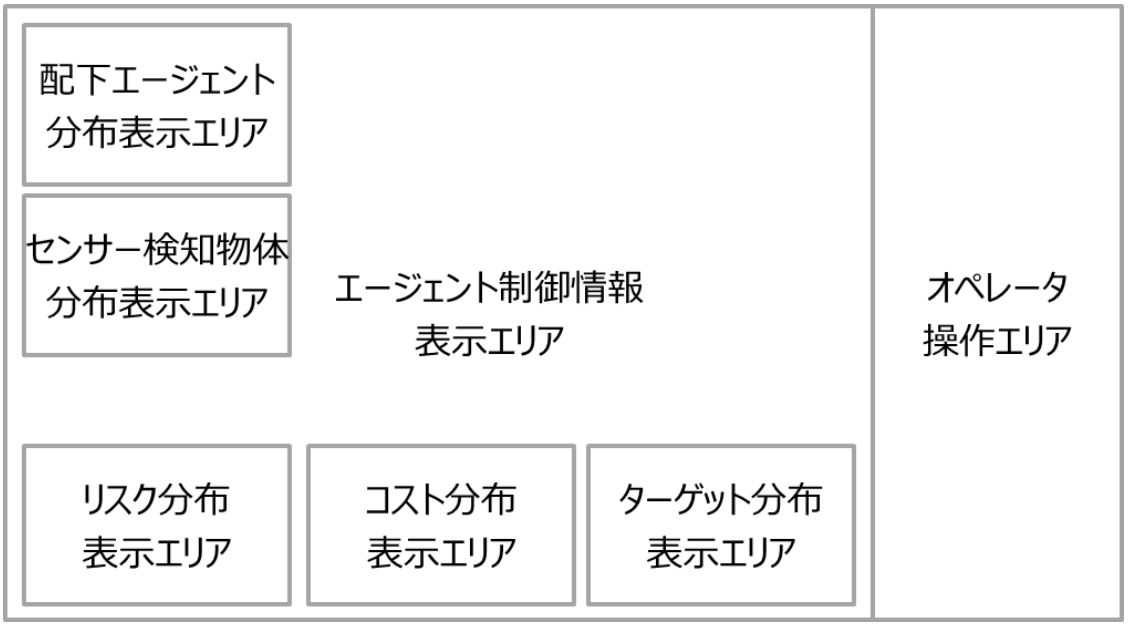

図 ３．５．４－２ ACS の画面レイアウト

表 ３．５．４－１ ACS の画面エリア

画面エリア名	説明
エージェント制御情報表示エリア	以下を表示する。 ・Physics.csv の NODE と LINE で定義された節点と線をもとにしたマップ ・各移動体のトラフィックソルバが作成した PATH、PMT ・各移動体の実機の現在位置とトラフィックソルバ内の現在位置
オペレータ操作エリア	オペレータがエージェント制御情報エリアの移動体や、各分布表示エリアに影響を与えるための UI（テキスト入力やボタン押下など）を提供する。
配下エージェント分布表示エリア	配下エージェントの密度分布を表示する。 オペレータ操作により、表示/非表示を切り替え可能。
センサ検知物体分布表示エリア	配下エージェントのセンサが検知した物体の密度分布を表示する。 オペレータ操作により、表示/非表示を切り替え可能。
リスク分布表示エリア	センサ検知物体に設定されたリスク値の分布を表示する。 オペレータ操作により、表示/非表示を切り替え可能。 オペレータ操作により、予測表示との切り替え可能。
コスト分布表示エリア	センサ検知物体に設定されたコスト値の分布を表示する。 オペレータ操作により、表示/非表示を切り替え可能。 オペレータ操作により、予測表示との切り替え可能。
ターゲット分布表示エリア	センサ検知物体に設定されたターゲット値の分布を表示する。 オペレータ操作により、表示/非表示を切り替え可能。 オペレータ操作により、予測表示との切り替え可能。

（２） 画面イメージ

ACSの各分布表示エリアを非表示にした場合の画面イメージは以下のとおり。ACSの各分布表示エリアを表示した場合の画面イメージは以下のとおり。

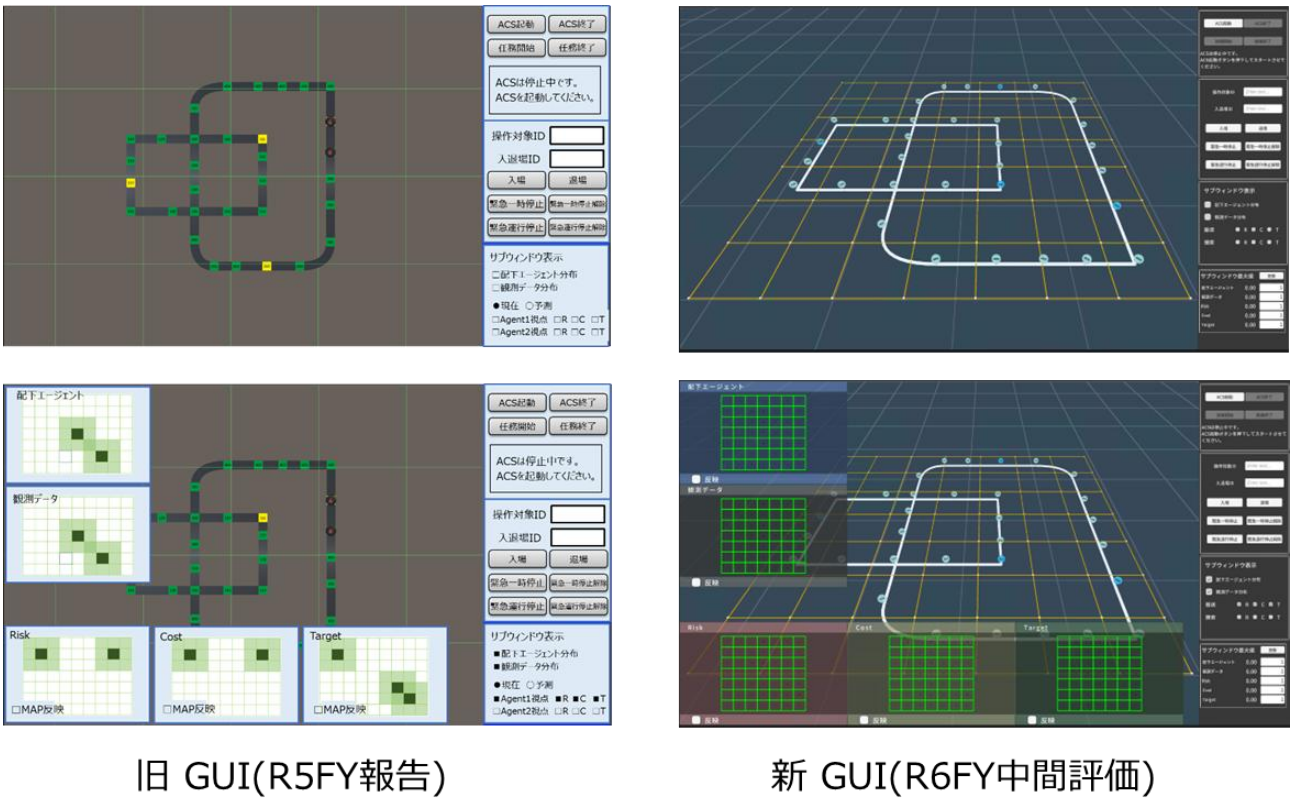

図 ３．５．４－３ ACS GUI 新旧比較

ACS の初期状態（各分布表示エリアを非表示にした場合）の画面イメージは以下のとおり。

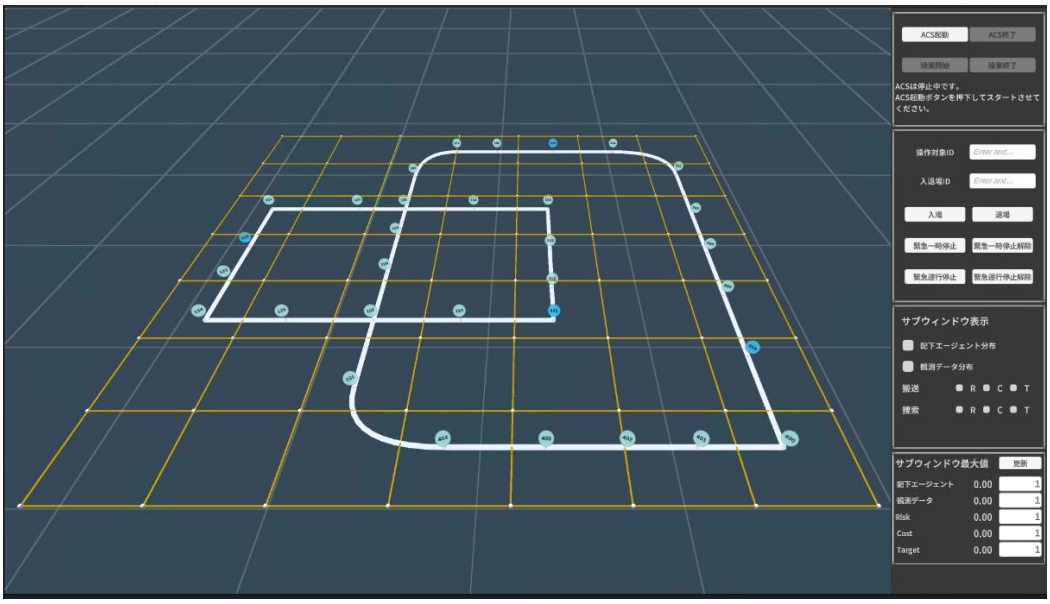

図 ３．５．４－４ ACS 画面イメージ(初期表示)

ACS の各分布表示エリアを表示した場合の画面イメージは以下のとおり。

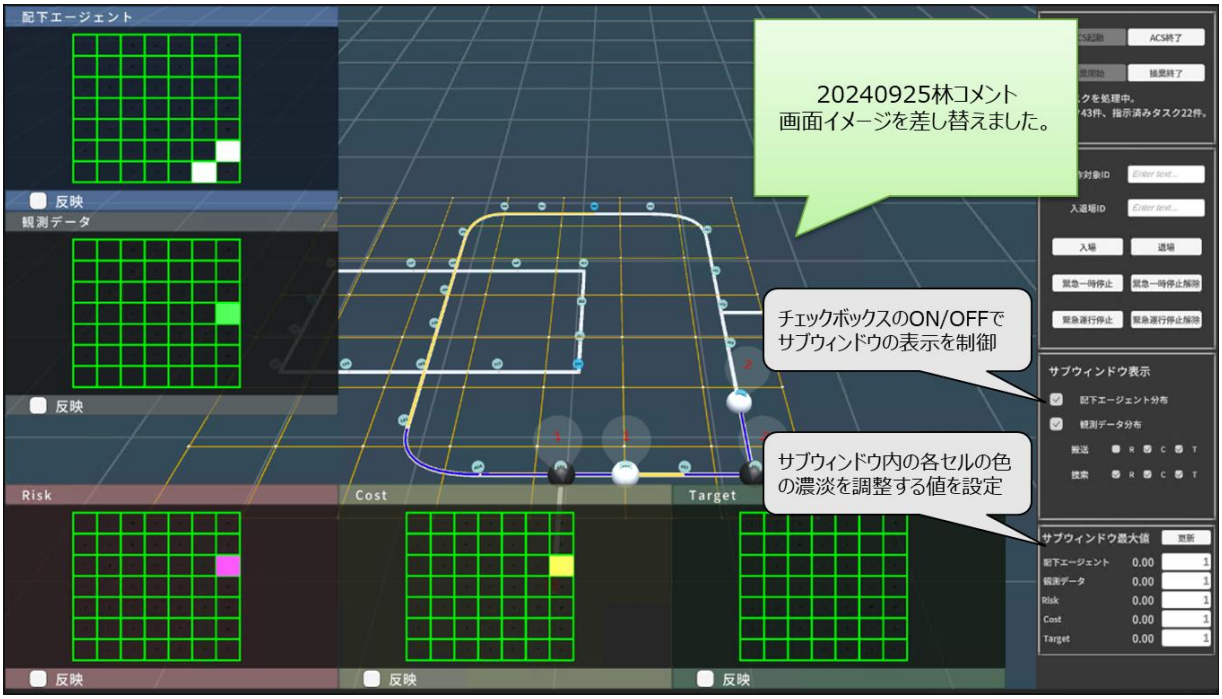

図　３．５．４－５　ACS 画面イメージ（サブウィンドウ表示状態）

ACS のシミュレーション時のアイコンやラインについて以下の図で説明する。

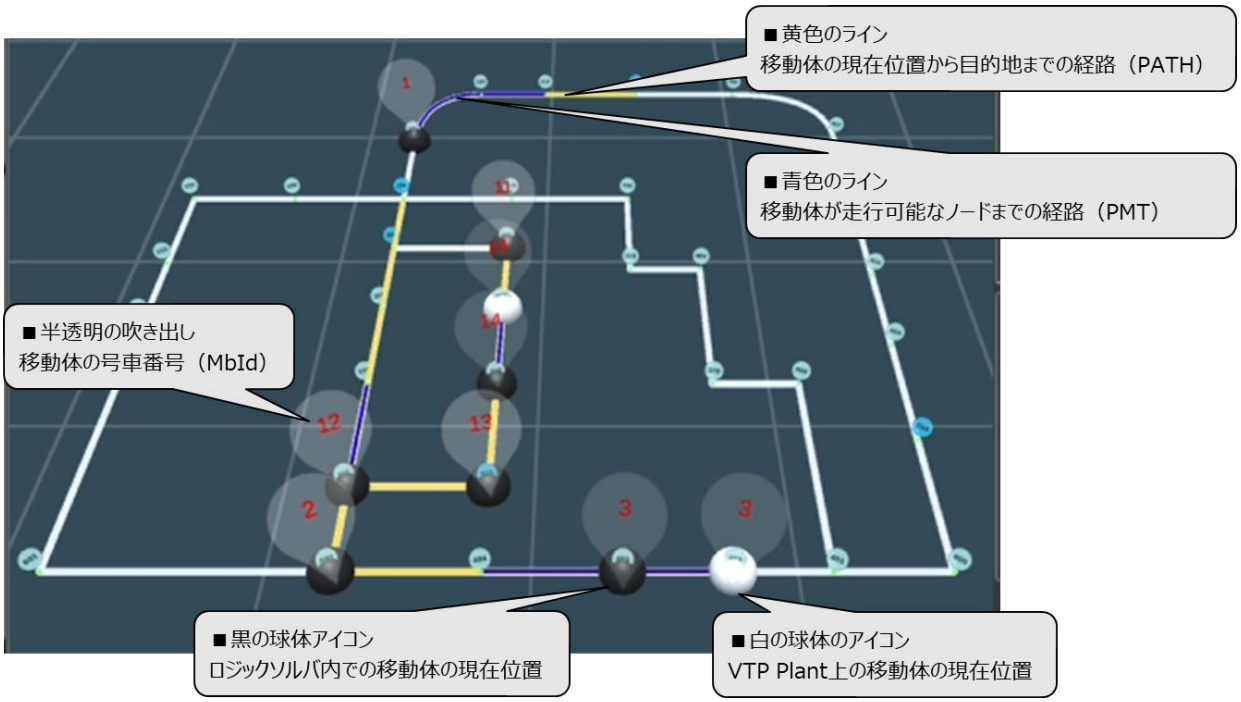

図　３．５．４－６　ACS のシミュレーション時の画面イメージ

タスク管理 AP の画面イメージは以下のとおり。タスク管理 AP により、「①タスクの状況」、「②グループ指定された移動体や目的地の割り当て結果」の情報を可視化した。

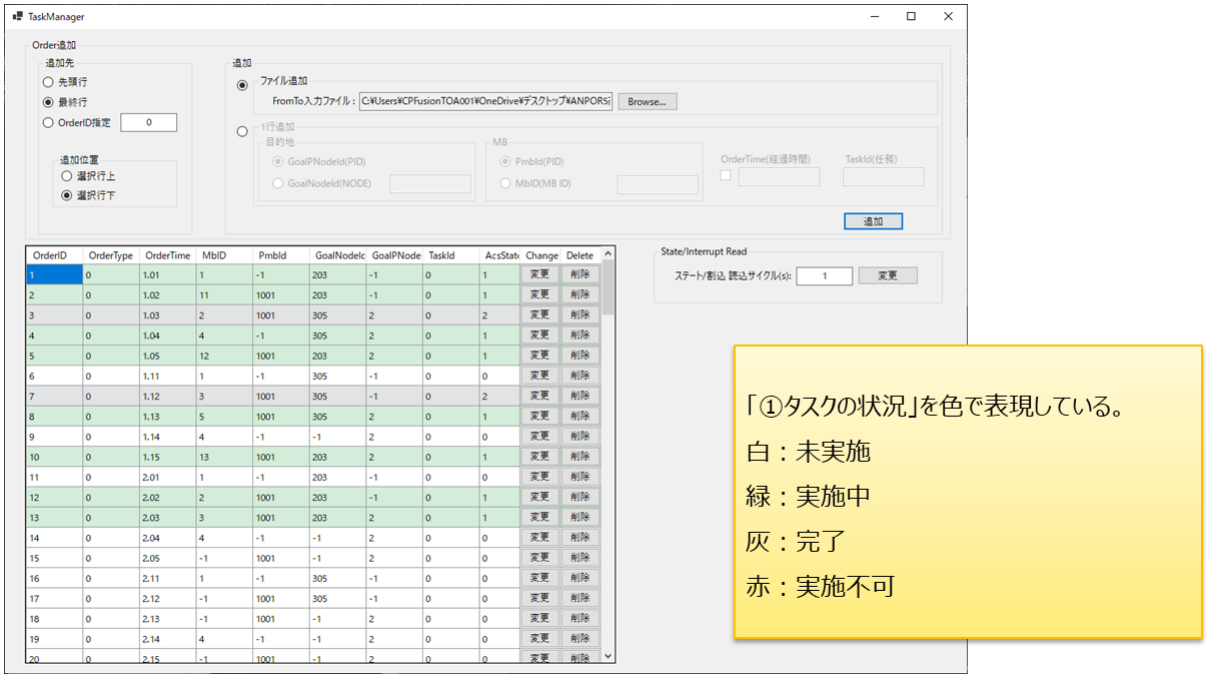

図　３．５．４－７　タスク管理 AP の画面イメージ

タスク管理 AP での「②グループ指定された移動体や目的地の割り当て結果」の情報を可視化については以下のとおり。「-1」（不定）から具体的な移動体の ID（赤枠部分）や目的地の ID（青枠部分）が割り当てられている。

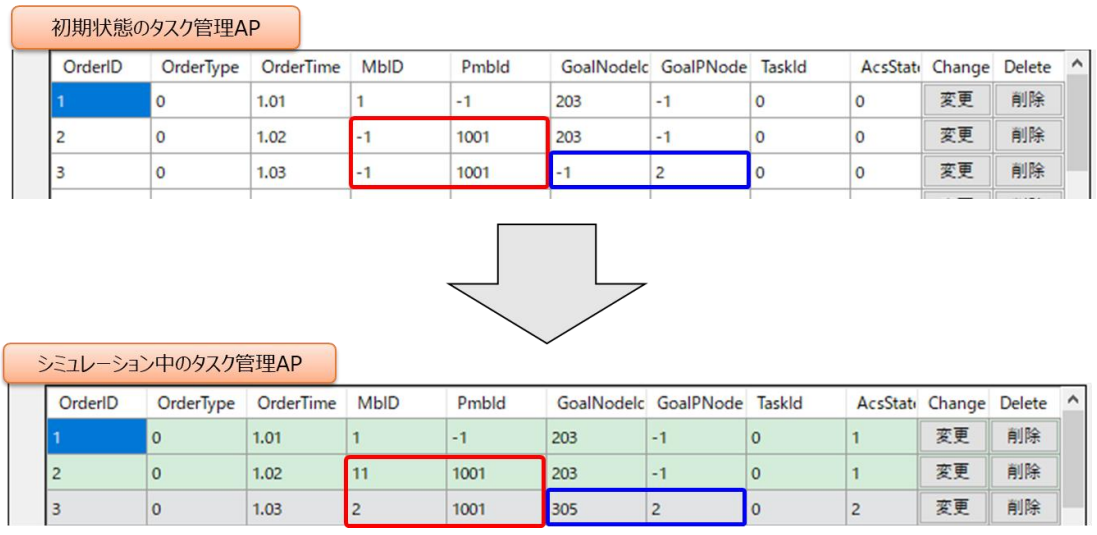

図　３．５．４－８　タスク管理 AP のグループ指定の割り当てイメージ

タスク管理 AP での「タスクの追加機能」は以下のとおり。ファイルでの複数タスク入力と、手入力での１タスク入力に対応した。

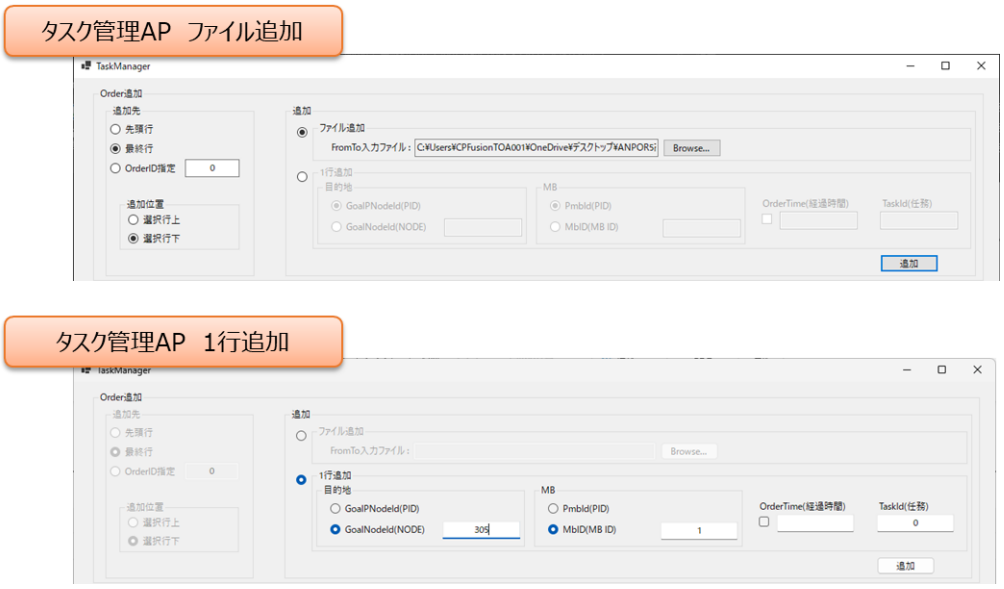

図　３．５．４－９　タスク管理 AP のタスク追加イメージ

タスク管理 AP での「タスクの変更・削除機能」は以下のとおり。入力されたタスクの変更・削除に対応した。　変更・削除可能なタスクは未実施タスクのみとしている。

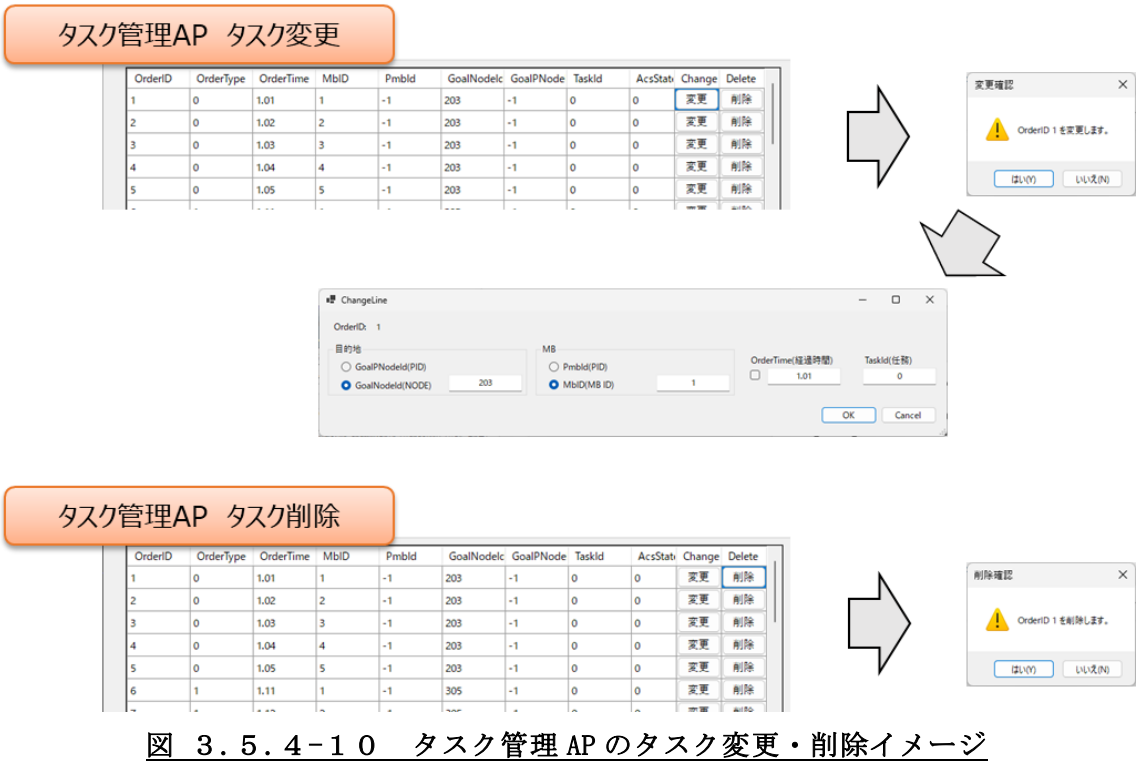

図　３．５．４－１０　タスク管理 AP のタスク変更・削除イメージ

（３） 画面アクション

ACSの画面アクションを表 ３．５．４-２に示す。

表 ３．５．４-２ システム開始終了時の画面アクション一覧

項目	内容
初期表示	Data フォルダ内の各種の入力ファイルを読み込む。Log フォルダ配下に出力ファイル（ログ、入力ファイル、統計情報ファイル、動画再生ファイル）の格納先フォルダを作成し、シミュレーションに使用する入力ファイルを Data フォルダからコピーする。コピーするファイルは VTPParam.csv で指定された入力ファイルのみを対象とする。ライセンスファイルの情報を読み込み、利用可能な PC 名、利用期限が条件を満たしているかをチェックする。条件を満たしていない場合、ポップアップを表示してアプリケーションを終了する。Physics.csv ファイルの NODE と LINE をもとにマップを表示する。プレイヤが複数存在する場合は、全プレイヤのマップをすべて表示する。
ACS 起動ボタン押下	以下の処理を行い、サーバ機能を開始する。 ● 移動体からの接続待ちを開始する。接続待ちポート番号は Communication.csv より取得する。移動体からの接続が完了すると、接続情報を元にマップ上に移動体を表示させる。 ● 他システムと連携する MMF を作成する。作成する MMF の詳細は「インターフェース定義書」を参照。 ● トラフィックソルバの初期化処理を行い、周期的な処理を開始する。 ● マップソルバの初期化処理を行い、周期的な処理を開始する。 ● タスクソルバの初期化処理を行い、周期的な処理を開始する。
ACS 終了ボタン押下	以下の処理を行い、サーバ機能を終了する。 ● 移動体との接続を切断する。 ● トラフィックソルバの周期的な処理を停止し、終了処理を行う。 ● マップソルバの周期的な処理を停止し、終了処理を行う。 ● タスクソルバの周期的な処理を停止し、終了処理を行う。

表 ３．５．４-３ 画面アクション一覧

No	画面アクション	処理内容
1	ACS起動ボタン押下	ACSのサービスを開始する。
2	ACS終了ボタン押下	ACSのサービスを終了する。
3	操業開始ボタン押下	タスクの処理を開始する。
4	操業終了ボタン押下	タスクの処理を停止する。
5	入場ボタン押下	控え状態の移動体をシミュレーション上に復帰させる。
6	退場ボタン押下	移動体をシミュレーション上から破棄し、控え状態にする。
7	緊急一時停止ボタン押下	移動体を一時停止させる。
8	緊急一時停止解除ボタン押下	移動体の一時停止を解除し、元の状態からシミュレーションを再開する。
9	緊急運行停止ボタン押下	移動体を停止させる。
10	緊急運行停止解除ボタン押下	移動体の停止を解除し、アイドル状態からシミュレーションを再開する。
11	配下エージェント分布チェックボックスON/OFF	配下エージェント分布のサブウィンドウの表示/非表示を切り替える。
12	観測データ分布チェックボックスON/OFF	観測データ分布のサブウィンドウの表示/非表示を切り替える。
13	タスクごとのRCTチェックボックスON/OFF	RCT分布のサブウィンドウの表示/非表示を切り替える いずれかのタスクの「R」にチェックがついていれば、Riskのサブウィンドウは表示される。すべての「R」のチェックを外すと、Riskのサブウィンドウは非表示となる。C、Tについても同様。
14	サブウィンドウ最大値の更新ボタン押下	サブウィンドウ内の各セルの色の濃淡を調整する値を設定する。

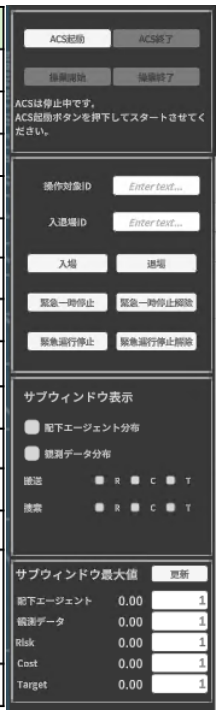

３．５．５ AI学習環境との連接

AI SLPFの学習の自動化向けに、AIソルバの行動a情報のインターフェースを提供する。

３．５．５．１ 起動モード

アプリケーション「仮想テストプラットフォーム（VTP：Virtual Test Platform）」は、起動モードを変更することで、VTP Plantモード、動画再生モード、ACSモードを切り替えることができる。AIの思想1、2の学習時、推論時向けにそれぞれ専用の起動モードを新規に定義した。

表 ３．５．５－１　起動モード一覧

起動モード	説明	自動開始	自動停止（※1）/csv出力	ロジックソルバのMMF利用（SolverParam.dat）	VTP PlantのMMF出力（Flag.dat、VTPPlant.dat）	ACSの問い合わせ	
						ロジックソルバ呼び出し	AIソルバ呼び出し（MMFによる同期制御）
0	VTP Plantモード（AIを利用しない）	－	－	－	－	－	－
1	動画再生モード	－	－	－	－	－	－
2	ACSモード（AIを利用しない）	－	－	○（※2）	－	○	－
10	AI思想1学習向けVTP Plantモード	○	○	－	○	－	－
12	AI思想1学習向けACSモード	○	－	○	－	○	－
20	AI思想1推論向けVTP Plantモード	－	－	－	○	－	－
22	AI思想1推論向けACSモード	－	－	○	－	○	－
30	AI思想2推論向けVTP Plantモード	－	－	－	○	－	－
32	AI思想2推論向けACSモード	－	－	－	－	－	○
40	AI思想2学習向けVTP Plantモード	○	○	－	○	－	－
42	AI思想2学習向けACSモード	○	－	－	－	－	○

※1 自動停止は、「VTP Plant上の全移動体がアイドル状態になってからの経過時間≧入力csvファイル（VTPParam.csv）の設定値」の条件を満たした場合にシミュレーションを終了する（操業終了ボタン押下相当）機能である。
※2 ACSがSolverParam.csvの値を初期値としてMMFに書き込んだ値を使用し、シミュレーション中に更新しない。

３．５．５．２ AI学習自動ループ構築手順

AI学習環境の自動化にむけては、チームメンバの認識を合わせながら、早い段階でフィジビリティの確認ができることを目的とし、以下のステップで進めた。

表 ３．５．５－２　AI学習自動ループ構築手順

ステップ	ステップ名称	改修	実施内容
1	静的パラメータチューニング（手動）	なし	**自動化認識共有と問題抽出：**提供済みのACS/VTP Plantを使用して手動でシミュレーションを行い、出力されるデータをもとにSolverParam.csvの最適なパラメータを導出するためのフローや必要なデータの洗い出しを行う。
2	静的パラメータチューニング（自動）	規模小	**自動化試行：**ステップ1で手動で実施していた操作を自動化する仕組みを備える。ステップ1で洗い出したAIへの入力情報として必要なデータを出力する。
3	動的パラメータチューニング（自動）	規模大	**自動化確立：**ステップ2で自動化した仕組みに加え、MMF（Memory Mapped File）を使用して、各システム間でデータを共有し、シミュレーション途中でもSolverParamの情報を更新できるようにする。

３．５．６ 高度化２「工場作業員誤侵入危険回避」対応

（１） RCT マップ・マップソルバ連携

マップを新たにセルという単位で区切り、セル単位でR（リスク）、C（コスト）、T（ターゲット）の情報を可視化することで、情報の抽象度が高められ、シミュレーションの情報を把握しやすくなる。また、AIの学習速度の向上に寄与させる狙いもある。

（ア）概要

マップソルバは、ACSがエージェントから受信した入力データを使用して、セル単位の密度やRCTの値を算出する。トラフィックソルバはRCTを元に、経路生成、交通制御を行う。ACSはマップソルバの算出した値をサブウィンドウの各セルの濃淡として可視化する。

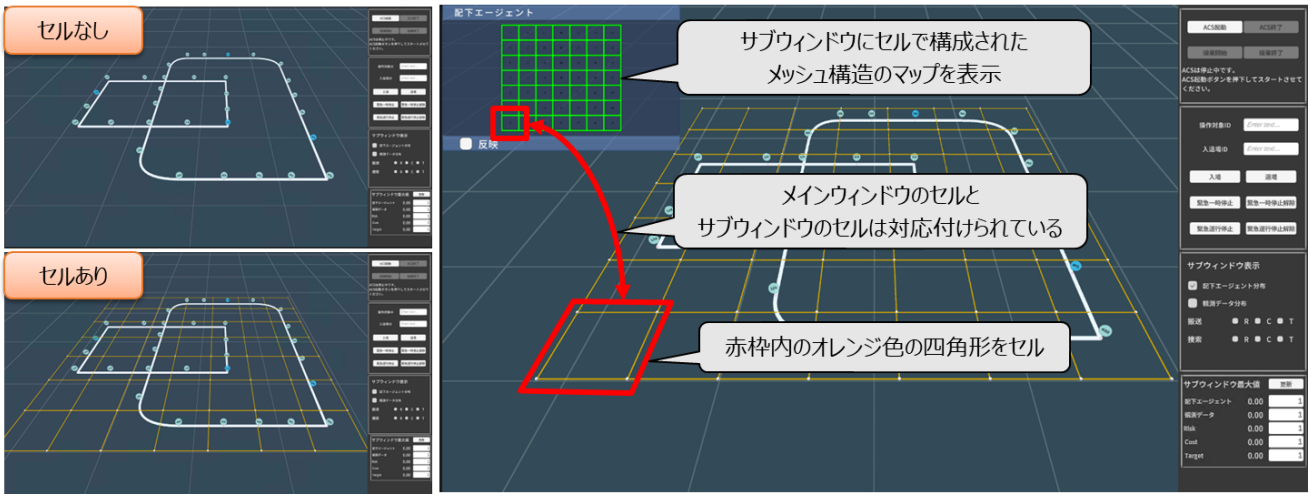

図 ３．５．６－１ ACS におけるセル、サブウィンドウの概要図

（イ）メインウィンドウとサブウインドウ

メインウィンドウのセルとサブウィンドウのセルは対応付けられており、サブウィンドウの「反映」チェックボックスをチェックすると、サブウィンドのセルの情報がメインウィンドウのセルに反映される。

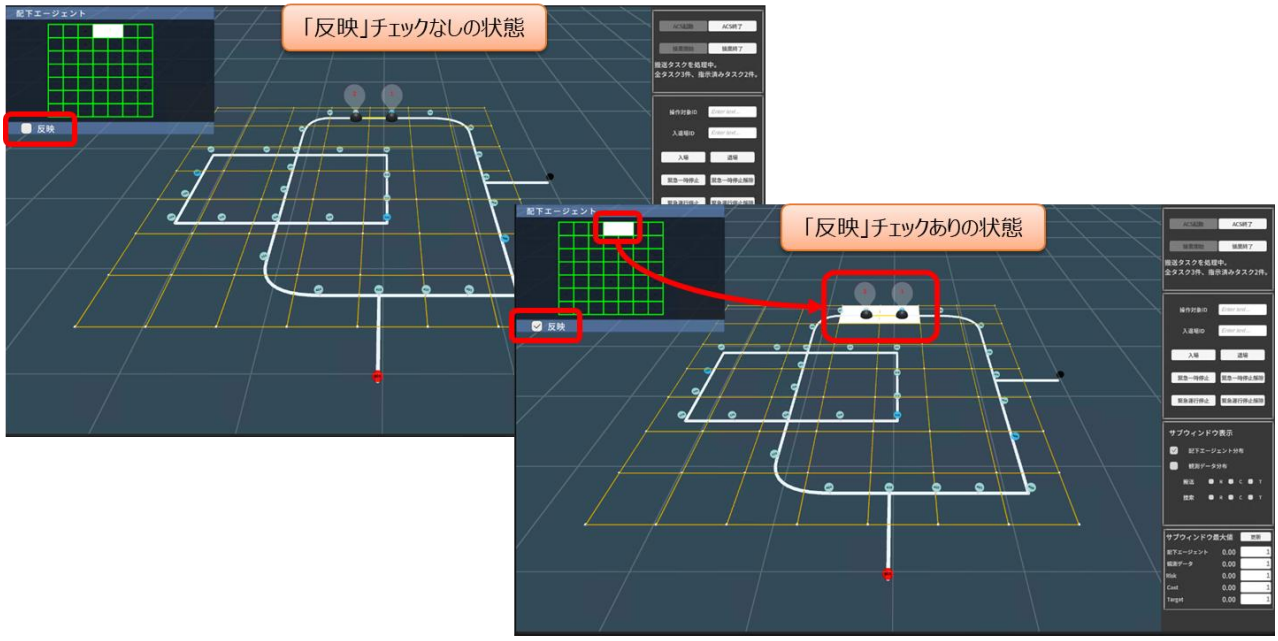

図 ３．５．６－２ ACS のサブウィンドウの反映機能

（ウ）サブウインドウ表示データ

ACSがエージェントから受信した以下のデータをマップソルバに連携することで、サブウィンドウに表示するマップのデータを取得できる。

①エージェントの現在位置（ノードID）
②エージェントの状態
③センサー検知データ

各データがどのサブウィンドウに影響するかを以下の図に示す。

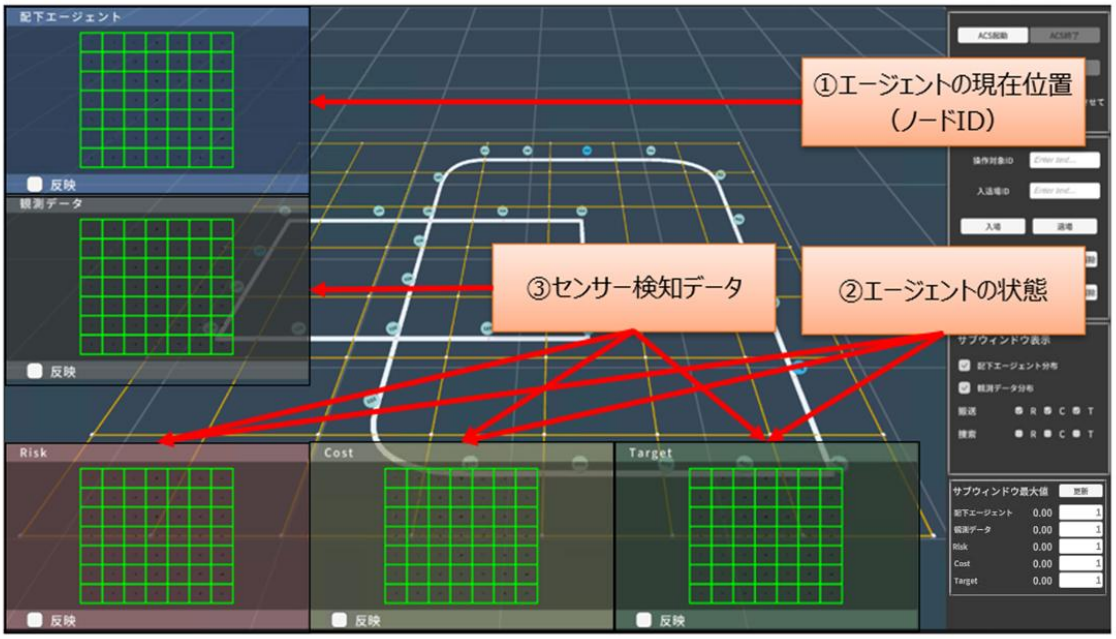

図　３．５．６－３　マップソルバへの入力データと影響するサブウィンドウの対応

（エ）連携画面イメージ

ACS とマップソルバの連携によるイメージ図を以下に示す。

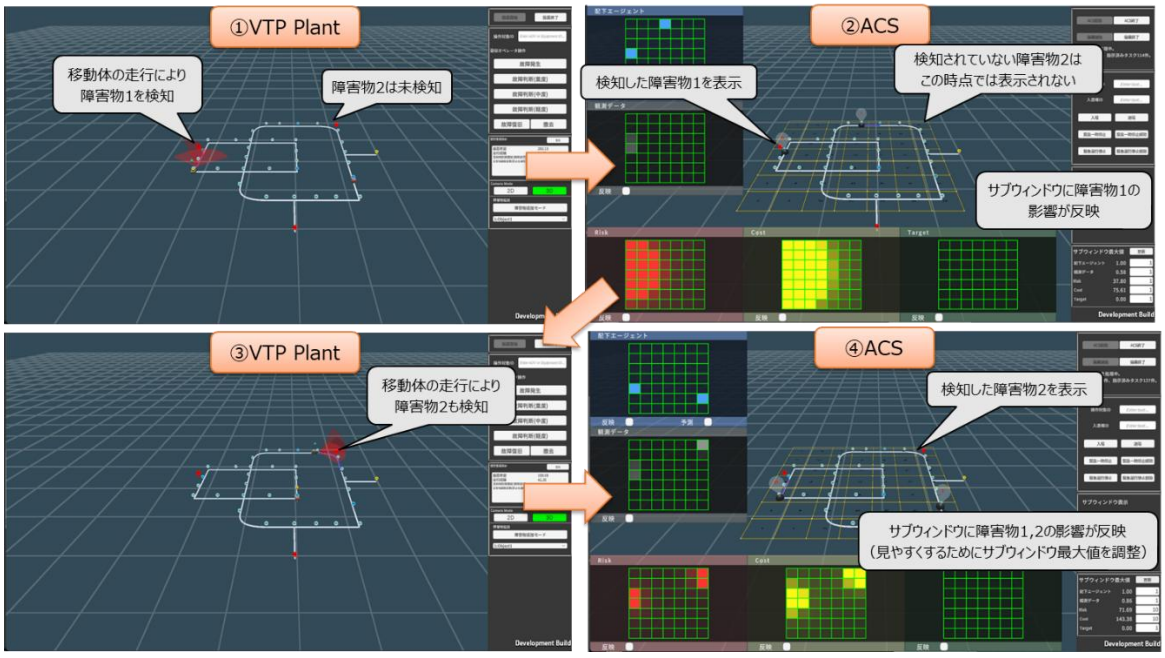

図　３．５．６－４　ACS とマップソルバの連携イメージ図

（オ）RCT 濃淡設定

マップソルバは移動体に割り当てられたタスクごとに各セルのR、C、Tを算出する。

同じ障害物であっても、タスクによってR、C、Tの影響が異なるためである。例えば、地上で通路を塞いでいる同じ障害物であっても、以下の①は影響を受けるが、②は影響を受けない。

①地上で救援物資を搬送するタスクを割り当てられた移動体

②上空から地上の救助者を捜索するタスクを割り当てられた移動体

上記に対応して、ACSのサブウィンドウ表示では、タスクごと（下図の例では「搬送」、「捜索」がタスク）にR、C、Tを選択する。同時に複数タスクのR、C、Tを選択した場合は、選択した各タスクのR、C、Tの合計値を使用して、サブウィンドウのセルの濃淡に使用する基礎値を決定する。

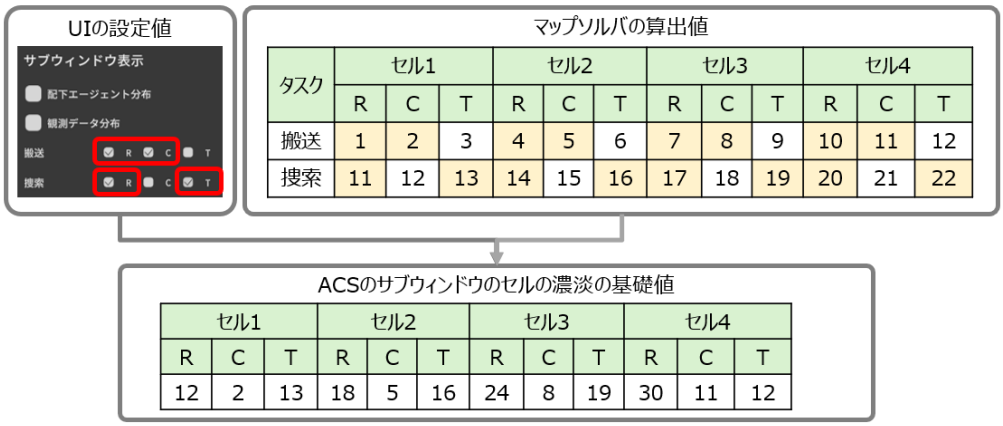

図　３．５．６－５サブウィンドウのセルの濃淡の基礎値の算出例

（カ）サブウインドウ最大値設定

サブウィンドウ最大値について補足する。

サブウィンドウ最大値は、サブウィンドウ内の各セルの濃淡を調整するために設定する値である。各セルに濃淡をつけることにより、直感的に状況を把握しやすくなる。

セルの濃淡は、以下の計算式によって決定する。

セルの濃淡＝ACSのサブウィンドウのセルの濃淡の基礎値 / サブウィンドウ最大値の値

（※）ACSのサブウィンドウのセルの濃淡の基礎値については前スライド参照

以下の図の例では、最大値が1に設定されているので、ACSのサブウィンドウのセルの濃淡の基礎値が1以上のセルは最大の濃さとなり、1より小さい値のセルは、値に応じた濃淡で表示される。濃淡に変化をつけたい場合は、シミュレーション中にマップソルバが算出した最大値が「サブウィンドウ最大値」にラベルとして表示される値（例えば、以下の例ではマップソルバが算出したCostの最大値は132.77）を参考にして、サブウィンドウ最大値を調整する。なお、マップソルバの算出した値に無限大の値が発生した場合は、数値の横に「*」を表示し、表示される数値は無限大の次に大きい値とする。

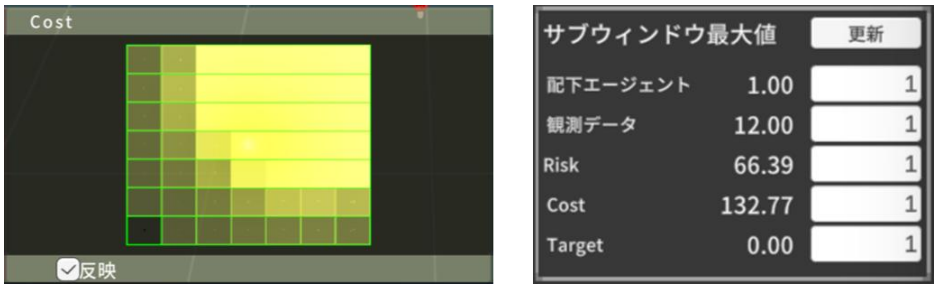

図　３．５．６－６サブウィンドウのセルの濃淡

（２） 突発事象対応

ACS から各移動体に対して、緊急停止および緊急停止解除の指示を出すことができる。
緊急停止には、緊急運行停止と緊急一時停止の 2 種類があり、それぞれの差異については以下の表のとおり。

図 ３．５．６－７緊急停止の差異一覧

No	項目	緊急運行停止	緊急一時停止
1	移動体の停止方法	急停止	急停止
2	移動体の PATH、PMT の保持有無	保持しない	保持する
3	解除後の状態	アイドル状態	一時停止前の状態
4	解除後の移動体の位置	直前に通過したノードにワープ	停止位置から再開

上記表の No.4 「解除後の移動体の位置」について補足する。
ノード 101、102、103、104 の順で移動体が走行していて、102 と 103 の間で緊急停止の指示を受信した場合、停止解除後の移動体の位置は、緊急運行停止の場合はオレンジ色のアイコン、緊急一時停止の場合は青色のアイコンの位置となる。

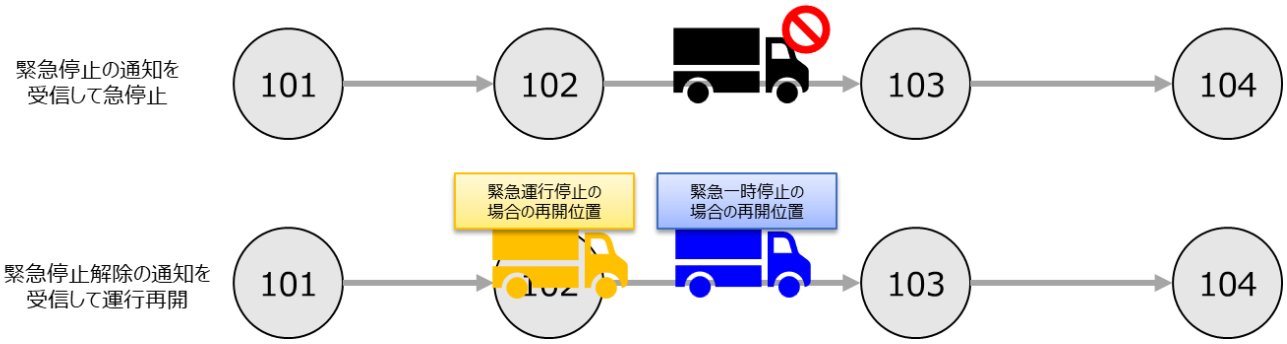

図 ３．５．６－８ 緊急停止解除後の移動体の位置

（３） 移動体の入退場対応

ACS から各移動体に対して、シミュレーション上からの破棄（退場）、復帰（入場）を指示することができる。シミュレーション上から破棄された状態を「控え」状態と定義する。

入退場の機能を利用するには、Physics.csv の PNODE_INOUT のデータモデルにて、
　　入場可能なノードは入口ノード
　　退場可能なノードは出口ノード
として定義する必要があり、定義されたノード以外からは入場、退場はできない。
また、同定義にて、入退場時の作業時間を定義することも可能である。

下図に入口ノード、出口ノードを定義した画面イメージを示す。
入場ボタンが押下されると、入口ノードに移動体が表示され、入場時の作業を開始し、作業が終わればアイドル状態となる。
退場ボタンが押下されると、退場用の割り込みタスク（出口ノードが目的地）が登録される。退場ボタンを押下時にすでに処理しているタスクがある場合は、そのタスクが完了後、割り込みタスクを開始して出口ノードに向かう。出口ノードにて、退場時の作業を行い、作業が終わればシミュレーション上から移動体が破棄される。

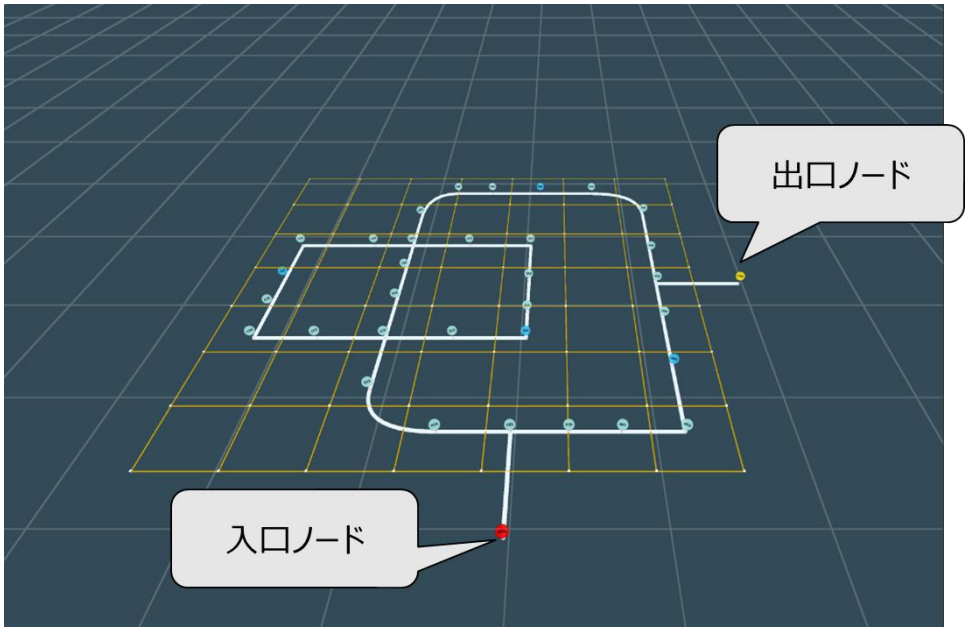

図 ３．５．６-９　入口ノードと出口ノードのイメージ

３．５．７ 高度化３「捜索・救難UAV/UGV混在3D化対応」

UAV をシミュレーションに追加するにあたって、エージェント制御情報表示エリアの 3D 化対応を実施し、立体的で奥行きのある UI を実現した。

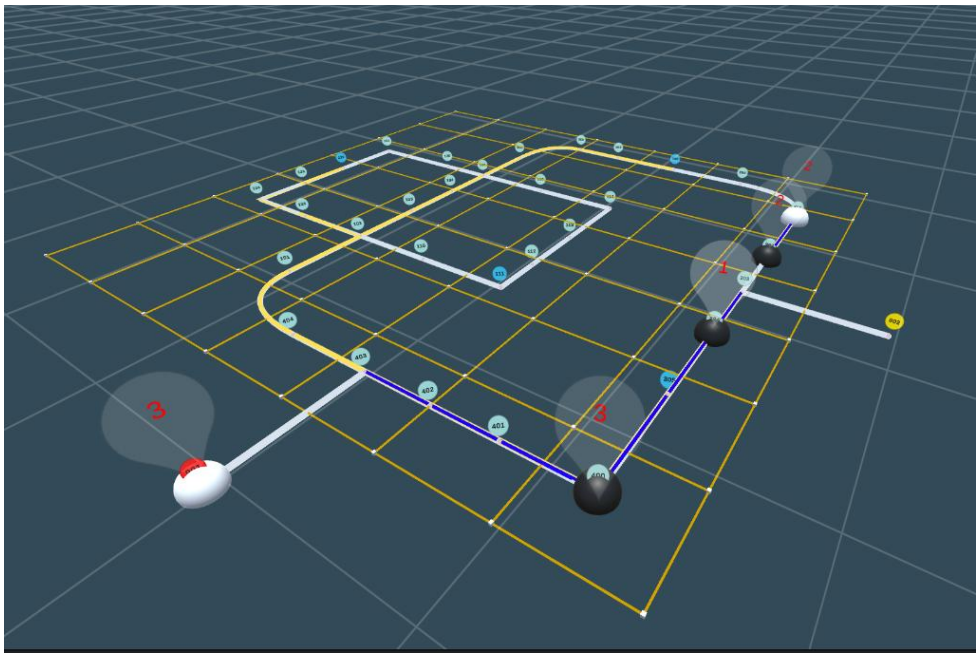

図　３．５．７－１ 3D 化対応した ACS のエージェント制御情報表示エリアのイメージ

空中を飛行する UAV が地上の UGV や障害物を探索するシミュレーション時のイメージを下図に示す。

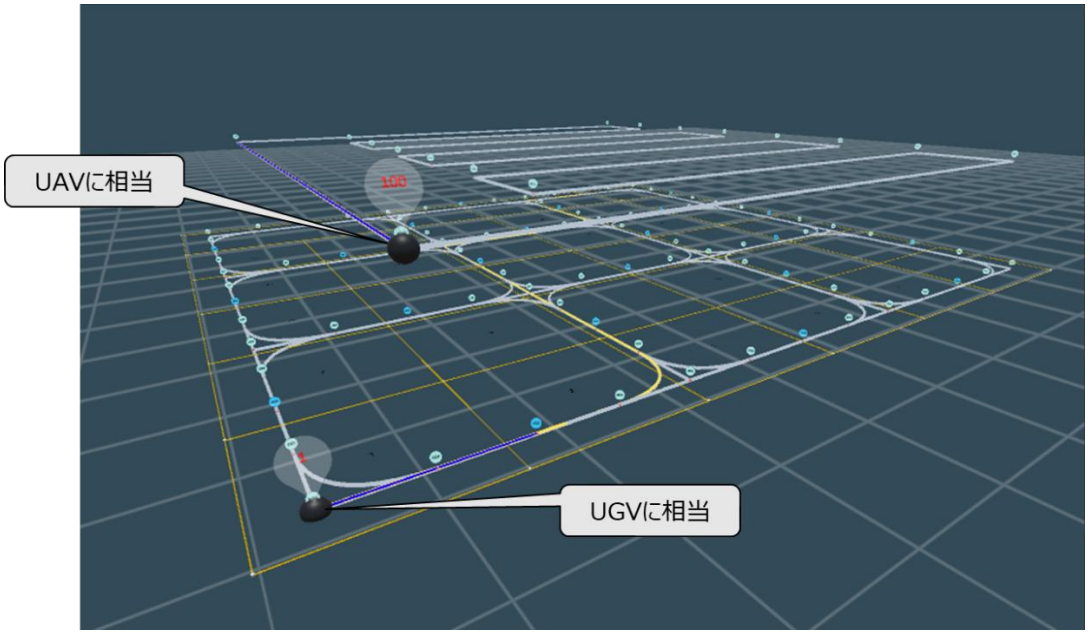

図　３．５．７－２　UGV/UAV シミュレーション時の ACS のエージェント制御情報表示エリアのイメージ

３．５．８ マップ切替

（１） 機能概要

任務の進行に伴う局面の変化が着目範囲の変化を伴う場合において、全体マップから部分マップに切替えてトラフィックの制御を行うことをマップ切替という。全体マップを大マップ、部分マップを中マップと表現する。

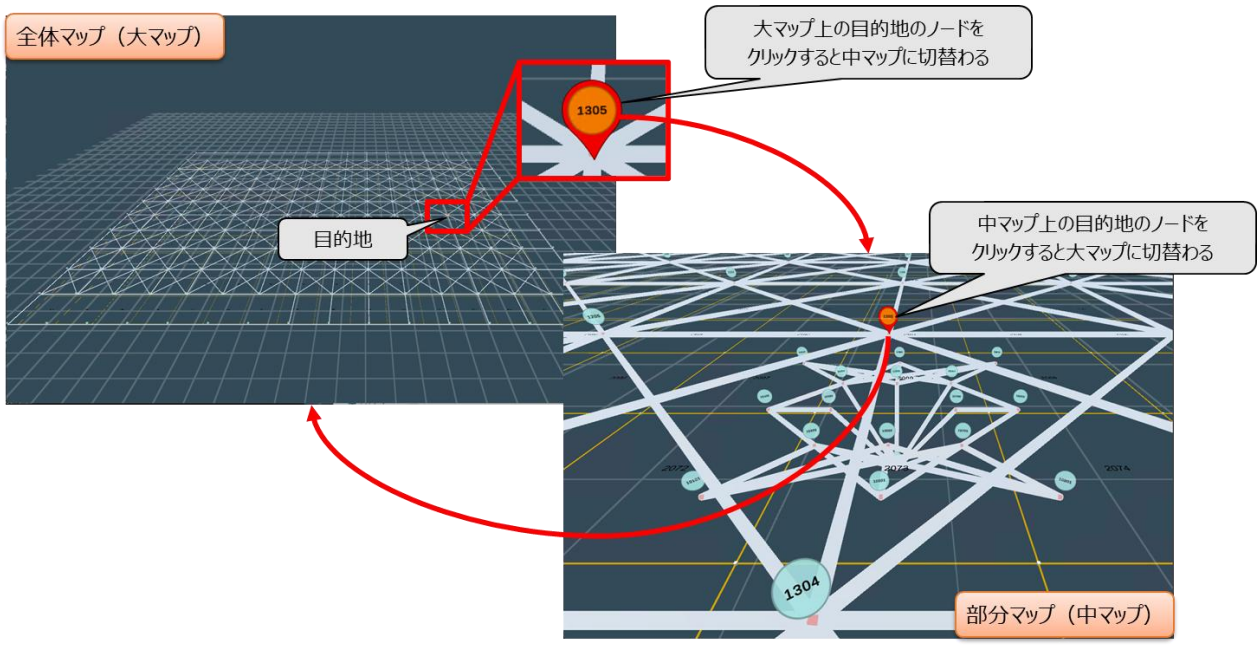

図 ３．５．８－１ ACS でのマップ切替のイメージ

（２） 起動モード

マップ切替機能を提供するにあたって、以下の起動モードを追加した。

起動モードの「100:VTP Plant モード（マップ切替）」と「102:ACS モード（マップ切替）」は、マップ切替に対応した VTP Plant、ACS の機能をそれぞれ提供する。

起動モードの「3:MoveTo エディタモード」は、マップ切替を利用するために必要な移動タスクのデータ作成機能を提供する。移動タスクのデータには、データモデル「MoveToSet」、「MoveTo」の２種類があり、このうち、MoveTo エディタモードでは、「MoveTo」のデータをマップ上のノードを確認しながら作成することができる。「MoveTo」のデータには、大マップ用と中マップ用のデータがあり、そのどちらも作成可能である。

データの詳細についてはデータモデル定義書を参照。

表 ３．５．８－１ マップ切替に関連する起動モード一覧

起動モード	説明	自動開始	自動停止（※1）/csv 出力	ロジックソルバの MMF 利用（SolverParam.dat）	VTP Plant の MMF 出力（Flag.dat、VTPPlant.dat）		
						ロジックソルバ呼び出し	AI ソルバ呼び出し（MMF による同期制御）
3	MoveTo エディタモード	—	—	—	—	—	—
100	VTP Plant モード・マップ切替	—	—	—	—	—	—
102	ACS モード・マップ切替	—	—	○	—	○	—

（３） MoveTo エディタモード

（ア）概要

起動モードの「3:MoveTo エディタモード」の大マップ用の移動タスクを設定する画面イメージは以下のとおり。

画面右下の「中マップのタスク設定画面に切替」ボタンを押下すると、中マップ用の移動タスクを設定する画面に切り替わる。

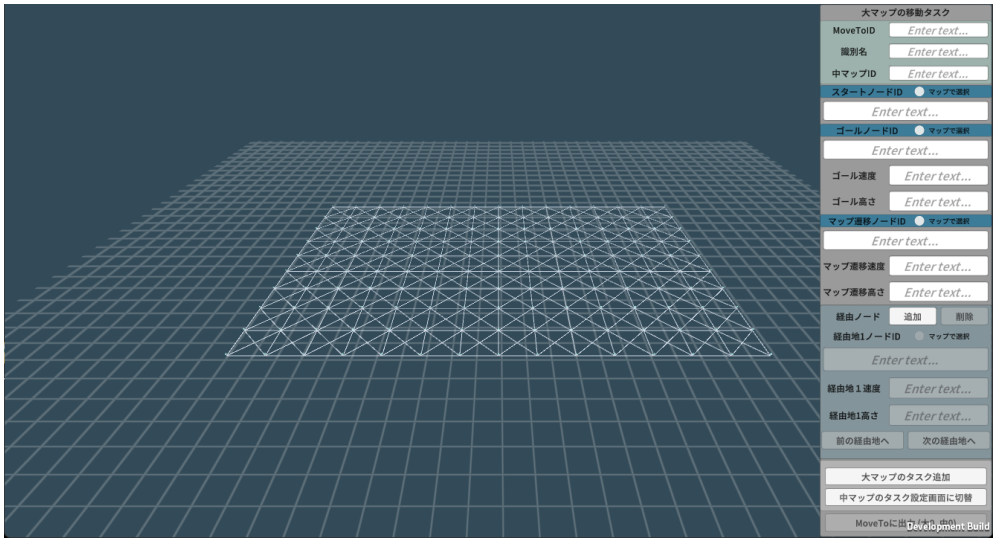

図 ３．５．８－２MoveTo エディタモードの大マップ用の移動タスク追加画面イメージ

（イ）タスク設定画面イメージ

起動モードの「3:MoveTo エディタモード」の中マップ用の移動タスクを設定する画面イメージは以下のとおり。

中マップのノードとラインのみが表示される（大マップのノードとラインは表示されない）。画面右下の「大マップのタスク設定画面に切替」ボタンを押下すると、大マップ用の移動タスクを設定する画面に切り替わる。

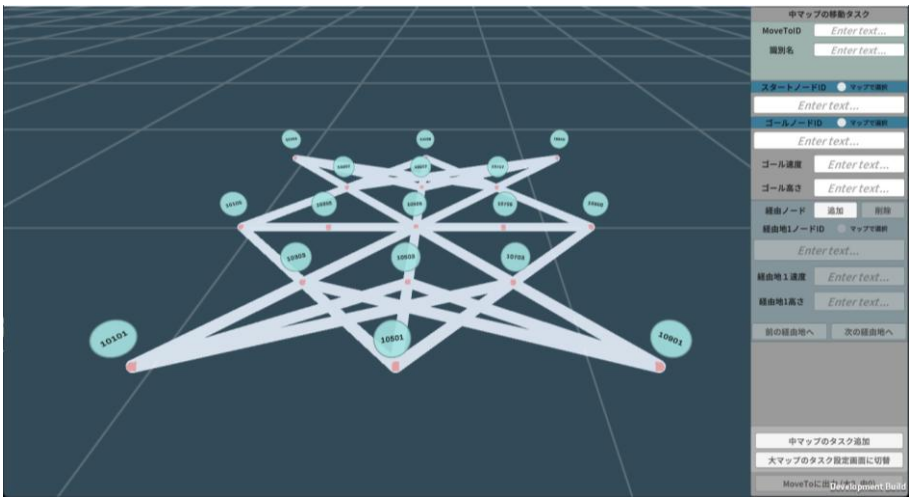

図 ３．５．８－３MoveTo エディタモードの中マップ用の移動タスク追加画面イメージ

（ウ）タスク追加マウス操作

起動モードの「3:MoveTo エディタモード」での各ノード ID の設定の方法として、入力フィールドで直接入力するほかに、

下図の赤枠の「マップで選択」のラジオボタンをチェックし、マップ上のノードをクリックすることでも設定可能である。

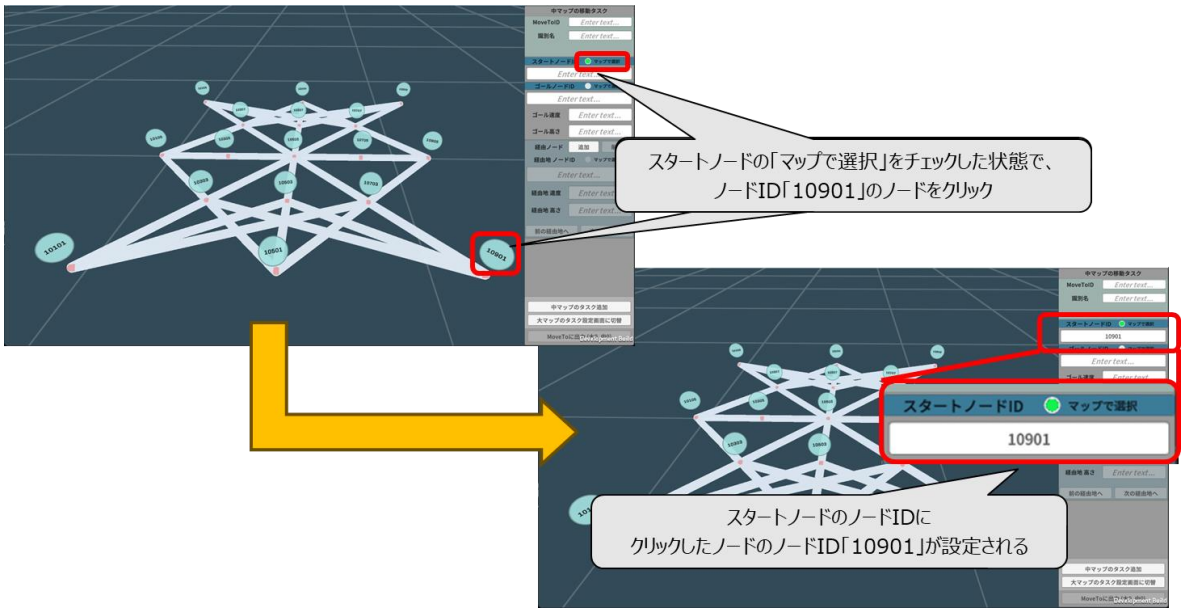

図　３．５．８－４　MoveTo エディタモードのノード ID の設定方法

（４）　タスク管理 AP 連携

マップ切替のシミュレーションを実行するためには、移動タスクのデータをもとに目的地を決定して、目的地を中心とした中マップのノード、ラインを生成する必要がある。そのため、マップ切替用のタスク管理 AP によって、シミュレーションする移動タスクのデータが MMF に書き込まれるまでは、ACS は待機用の画面を表示する（VTP Plant も同様）。

状態	マップ切替用タスク管理アプリの画面イメージ	ACSの画面イメージ
①初期 ACSは移動タスクのデータが未連携のため、待機する旨のメッセージのみを表示した画面となる	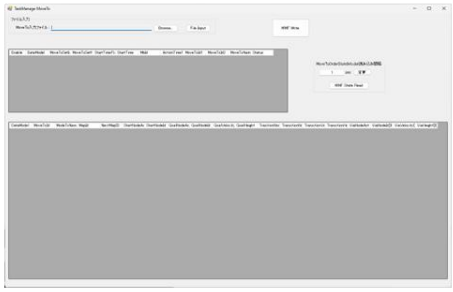	
②移動タスクのデータ連携（※）後 ※マップ切替用タスク管理アプリにて移動タスクのデータを保持したcsvファイルを取り込み、画面上部の一覧にて、MoveToSetのデータを選択して、「MMF Write」ボタンを押下すること	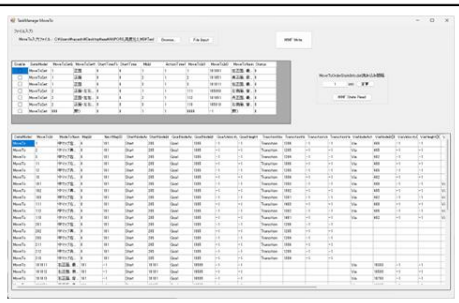	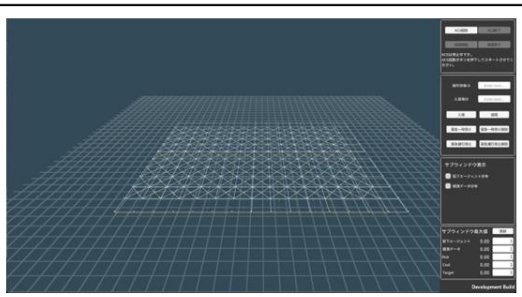

図　３．５．８－５　マップ切替のタスク管理 AP との連携イメージ図

（５） タスク管理 AP 画面イメージ

タスク管理 AP の画面イメージは以下のとおり。タスク管理 AP により、「タスクの状況」の情報を可視化した。

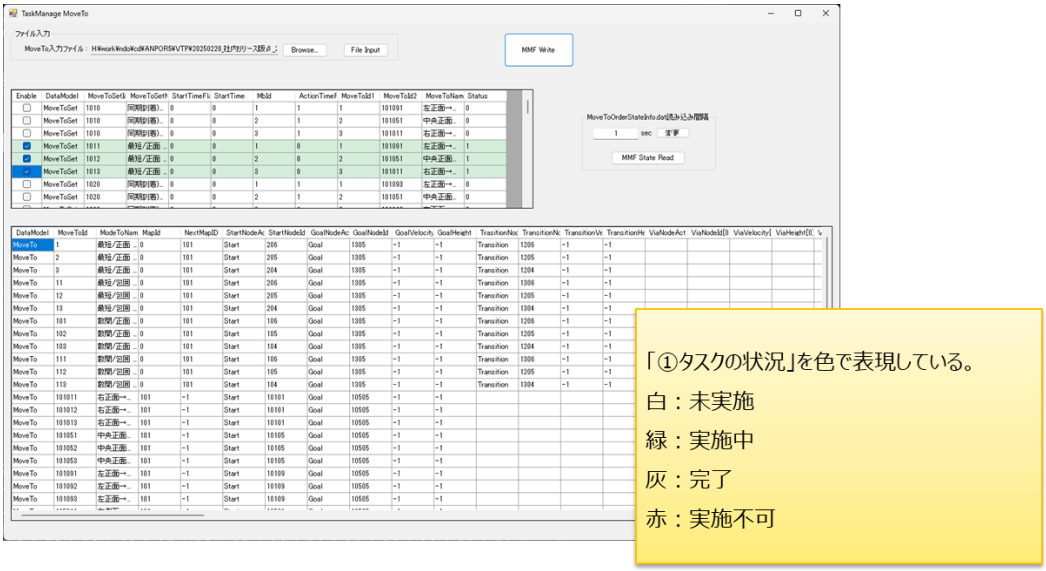

図 ３．５．８－６タスク管理 AP の画面イメージ

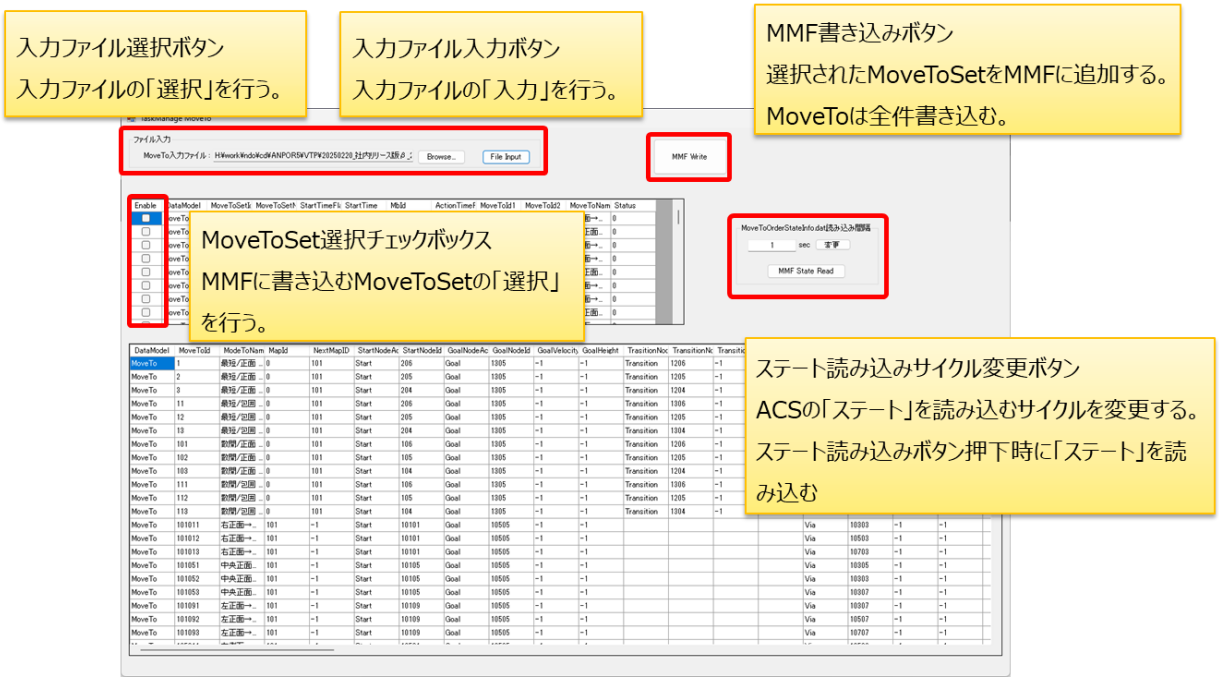

図 ３．５．８－７ タスク管理 AP の UI

タスク管理 AP での「タスクの追加機能」は以下のとおり。ファイルでの複数タスク入力に対応した。タスクをチェックボックスで選択し MMF へ書き込むことで ACS とタスク連携する。

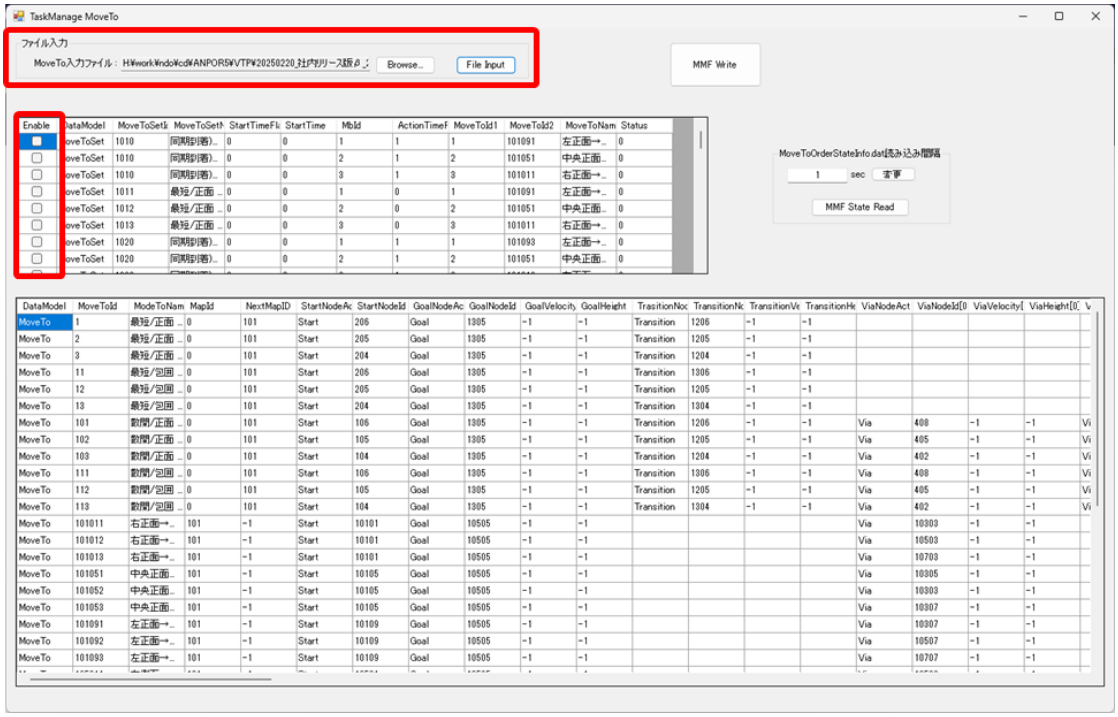

図　３．５．８－８　タスク追加

３．５．９ ノード・ライン表示制御

マップのノードやラインが複雑に重なり合ったり、異なる高さを持っていたりする場合に、シミュレーション状況を把握しやすくすることを目的として、ノード特性、ライン特性ごとに表示を制御する仕組みを提供する（本機能は VTP Plant でも同様の UI で提供する）。画面右下の「設定」ボタンを押下すると、「表示設定」のメニューに切り替わり、ノードとラインを「表示」、「非表示」、「半透明」のいずれかに設定できる。

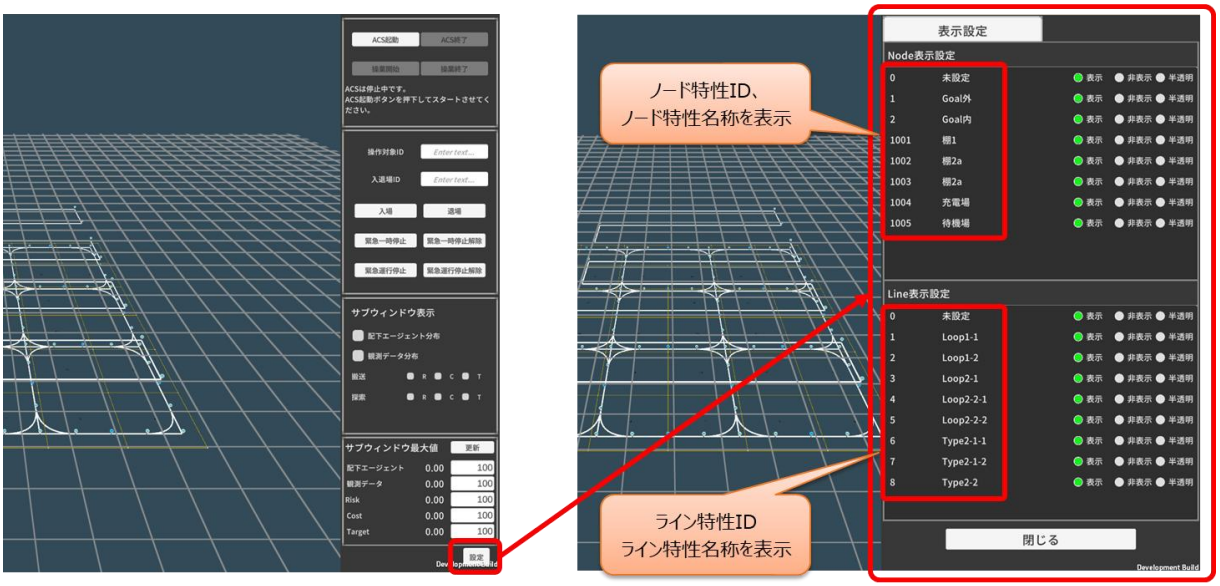

図　３．５．９−１ノード・ライン表示制御機能

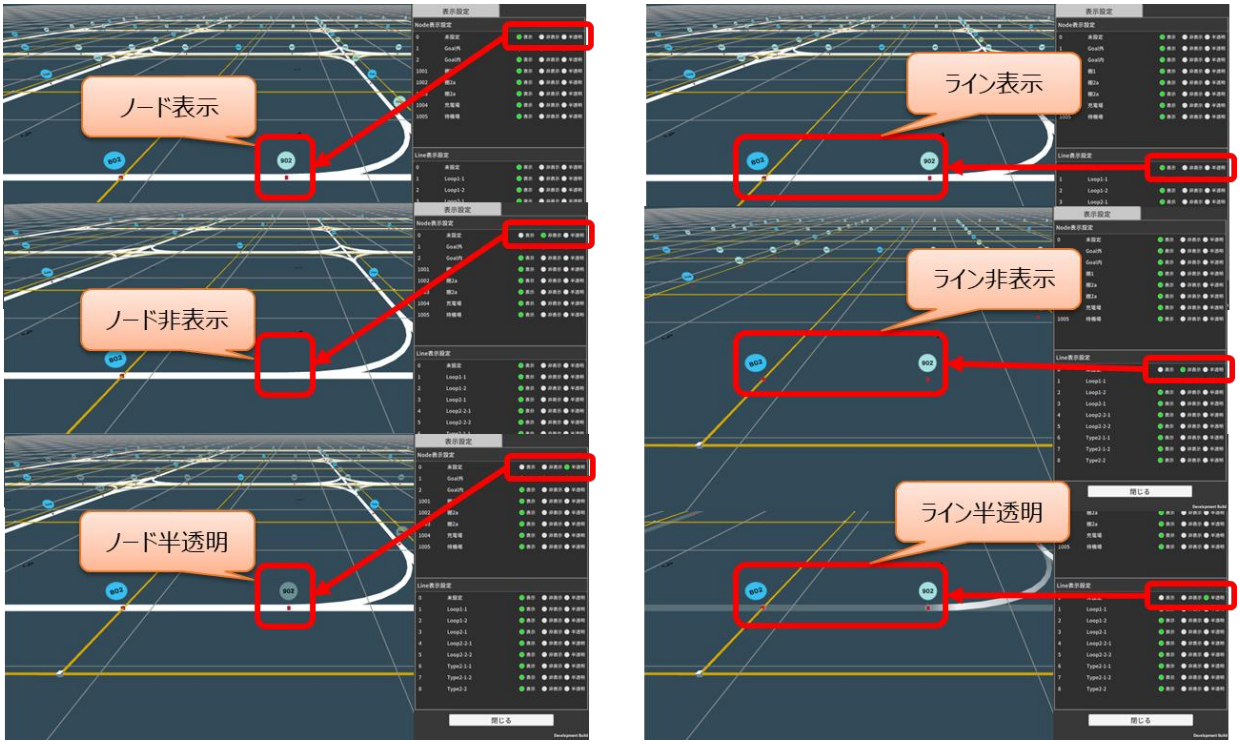

図　３．５．９−２ノード・ラインの表示、非表示、半透明イメージ

３．６　実施項目⑤仮想テスト環境の構築と試験実施

３．６．１ 成果概要

実用シナリオ「工場倉庫のAGV搬送」の突発事象対応として、障害物追加機能、センサ検知機能、故障管理機能を実装した。実用シナリオ「重要拠点のUxV遠隔監視」で使用するUAVに対応するために、GUIの2D→3D化を実施した。AI SLPF向けに学習用、推論用の起動モード、および、学習に必要な情報の連携機能を実装し、自動学習環境の構築を進めた。

また、実機システムと連携させ、VTP Plant上に仮想MBと実機MB、仮想障害物とリアル障害物をそれぞれ表現した。

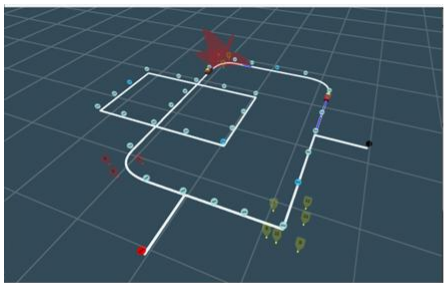

VTP Plantでの障害物検知イメージ

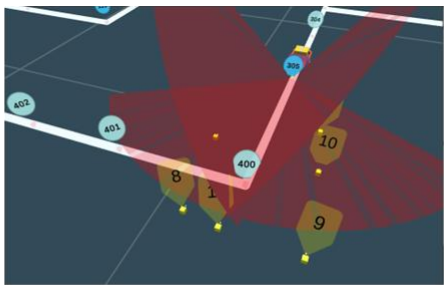

VTP Plantでの障害物検知イメージ（拡大）

故障管理機能

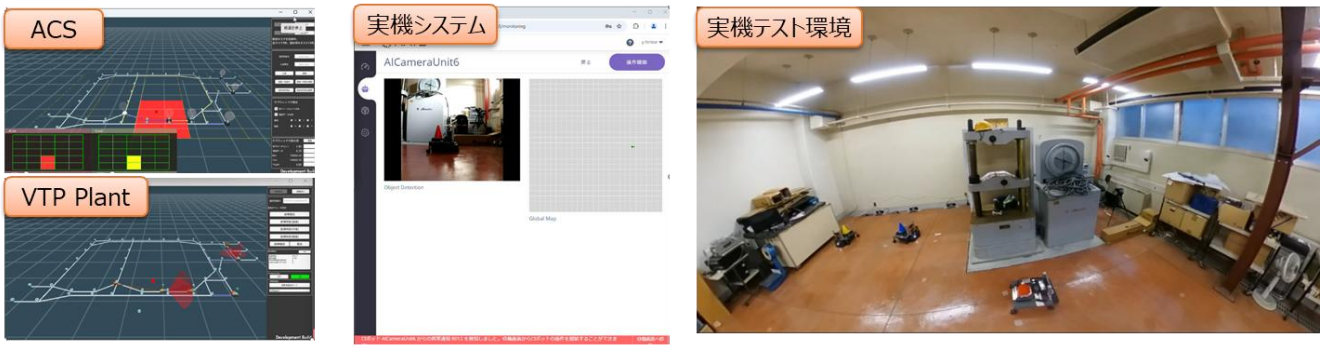

VTP Plantと連携する実機システムのイメージ

図　３．６．１－１　仮想テスト環境 VTP Plant 成果概要

３．６．２ システム概要

VTP Plant（VTP：Virtual Test Platform）はマルチエージェントシミュレータとして、マップ上に複数の移動体機能を仮想化し、移動体制御、搬送アルゴリズムの正常性・品質を検証するためのアプリケーションである(図　３．６．２－１参照)。VTP Plantは、アプリケーション「仮想テストプラットフォーム（VTP）」のVTP Plantモードとして実装する。

システム全体におけるVTP Plantの位置付けは以下のとおり。

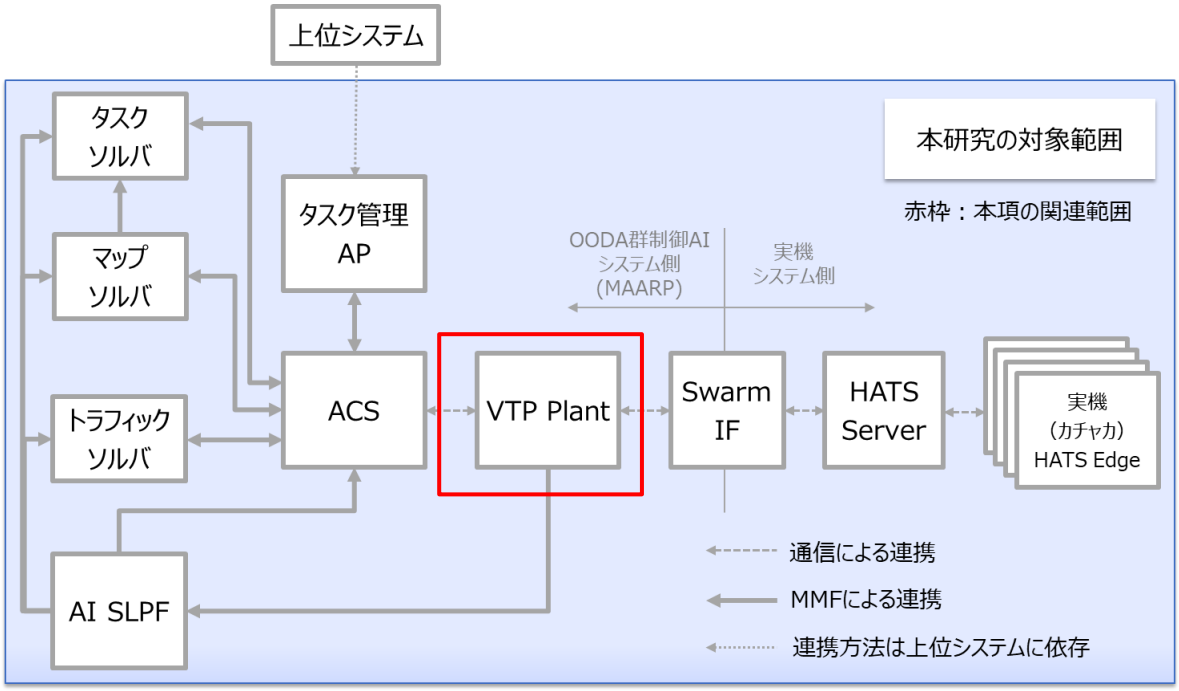

図　３．６．２－１　システム概要図

３．６．３ 仮想化オブジェクト

３．６．３．１ 任務フィールド

任務フィールドは、移動体の経路やプレイヤやAIの認知思考用マップモデルでモデル化される。Physics.csvファイルをもとにマップを表示する。プレイヤが複数存在する場合は、全プレイヤのマップをすべて表示する。詳細は、可視化機能を参照のこと。

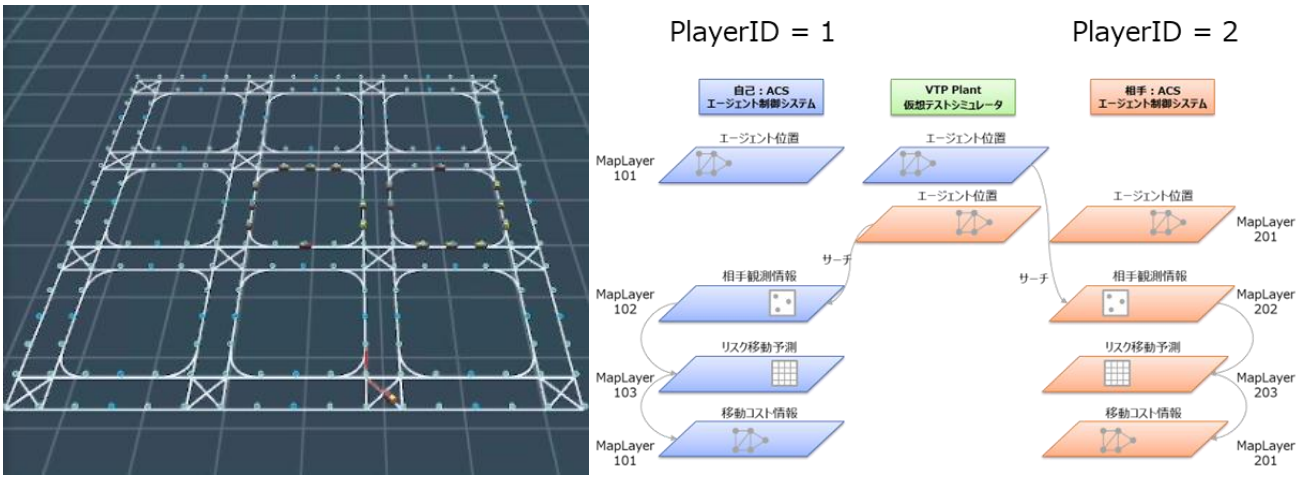

VTP画面　　マルチプレイ対応任務フィールド

図　３．６．３-１任務フィールドの画面イメージ

３．６．３．２ 移動体

（１）　移動体の種類

ロジックソルバの「３．４．３．４　移動体モデル」を参照のこと。

（２） 移動体の状態

移動体の状態は以下の11種類である。移動体の状態は、移動体の上部に表示する八面体のアイコンの色によって可視化している（色は設定により変更可能）。

表 ３．６．３－１ 移動体の状態

No	状態名	説明
1	PowerOn	電源 ON 状態（今後使用しない予定）
2	PowerOff	電源 OFF 状態（今後使用しない予定）
3	Charge	エネルギーチャージ状態
4	Run	走行状態
5	Idle	アイドル状態
6	Work	作業状態
7	Turn	旋回状態
8	Wait	待機状態
9	Trouble	トラブル状態（現状、使用していない）
10	Stop	緊急停止状態（必要であれば今後追加予定）
11	Reserve	控え状態（必要であれば今後追加予定）

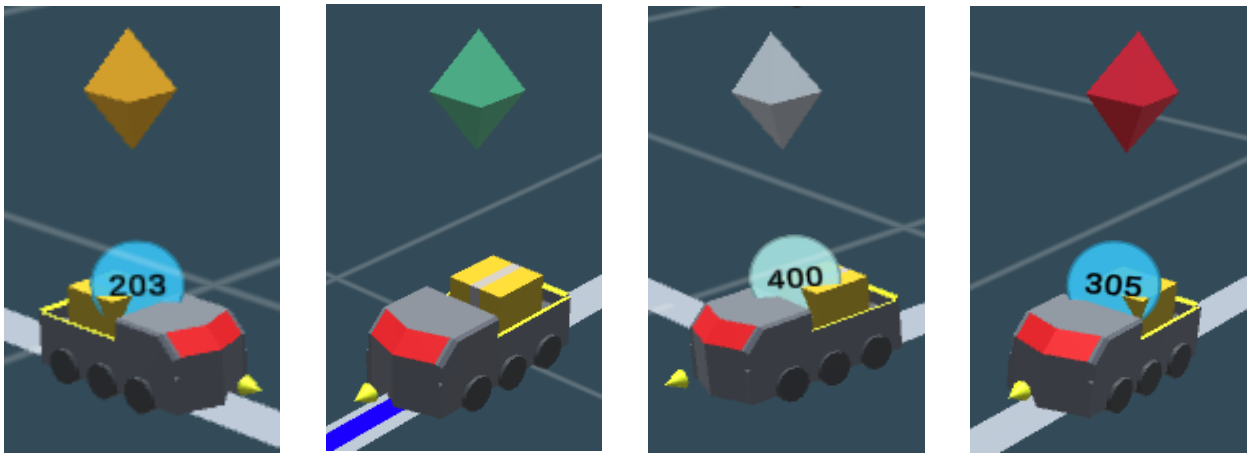

図 ３．６．３－２ 移動体の状態の可視化例

（３） 移動体のエネルギーチャージ

移動体は定期的にエネルギーチャージ率をACSに送信する。ACSはこの情報をタスクソルバに連携し、タスクソルバの指示を受けて、ACSはエネルギーチャージ率の低下した移動体に対してエネルギーチャージのタスク指示を出す。

※エネルギーチャージ率が低下したことを検知したタイミングで処理しているタスクはそのまま処理を継続し、処理中のタスク完了後に、エネルギーチャージのタスクを処理する。

エネルギーチャージ率は以下の計算式で算出する。最小値は0、最大値は100とする。

- エネルギーチャージ状態以外の場合(エネルギー消費する場合)

エネルギーチャージ率
＝現在のエネルギーチャージ率 ― エネルギー消費率(%/m) × 走行距離(m)

- エネルギーチャージ状態の場合

エネルギーチャージ率
＝現在のエネルギーチャージ率 ＋ エネルギーチャージ速度(%/s)×充電時間(s)

移動体はACSからエネルギーチャージ場所に向かうタスク指示を受けると、目的地であるエネ

ルギーチャージ場所にてエネルギーをチャージするために、以下の①～③のいずれかの条件を満たすまでその場に留まる。

① エネルギーチャージ率が PMB にて定義された「エネルギーチャージ終了可残量（閾値）の値を超えた場合
② エネルギーチャージ時間が PMB にて定義された「エネルギーチャージ終了経過時間（閾値）以下の項目の値を超えた場合
③ 満充電になった場合

（４） 移動体の作業

移動体はACSから作業場所に向かうタスク指示を受けると、目的地である作業場所にて作業を行うために、作業時間だけその場に留まる。
作業時間は移動体自身が作業するために要する時間と、作業場所でのオペレーションや設備などが要する時間が存在するため、以下のように決定する。

- PMB にて定義された「PmbActionOnOff」が OFF の場合
  PNODE にて定義された「作業時間 0：PnodeActionTime[0]」を作業時間とする。

- PMB にて定義された「PmbActionOnOff」が ON で、PNODE にて定義された「移動体特性 Pmb の作業 ID ：PnodePmbAction」が N（N=0～4）の場合
  以下の①、②を比較して、大きい値を作業時間とする。
  ① PMB にて定義された「作業時間 N：PmbActionTime[N]」
  ② PNODE にて定義された「作業時間 0：PnodeActionTime[0]」

（５） 移動体の走行制御

移動体はACSからPATH、PMTを受信して、その指示に従って走行する。
PATHとは、移動体の現在位置から目的地までの経路情報である（下図の黄色のライン）。経路情報には、目的地までに通過するノードID、走行動作、制限速度情報を含む。ACSが目的地を決定または変更したタイミングでPATHを送信する。
PMTとは、目的地までの経路のうち、移動体がどのノードまで走行可能かを示す情報である（下図の青色のライン）。PMTの端部が目的地に到達するまで、複数回受信し、徐々に端部が目的地に近づいていく。ACSが全体の状況を判断して、任意のタイミングでPMTを送信する。

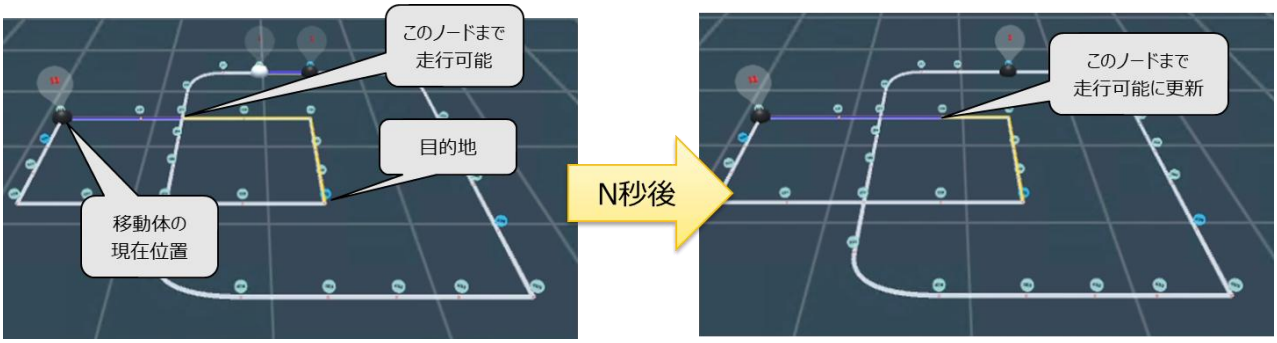

図 ３．６．３－３ PMT の時間経過による更新

（６） 移動体の通信インターフェース

移動体の走行制御に関する通信フローは以下の図のとおり。別紙「インターフェース定義書」を参照。

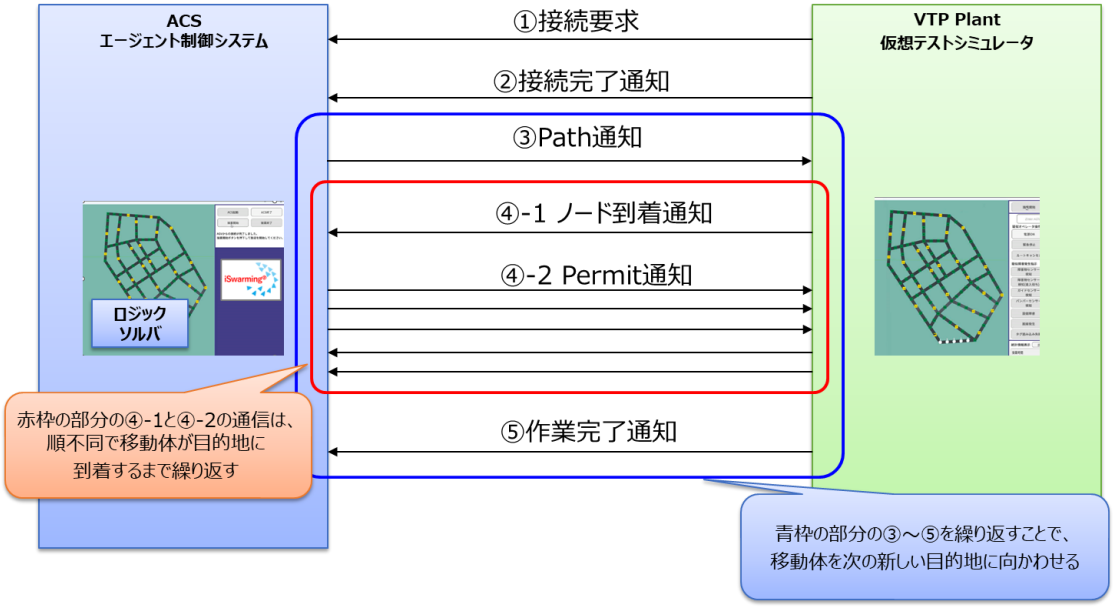

図 ３．６．３－４ VTP Plant－ACS 間間連携フロー概要図

３．６．３．３ 通信遅延

VTP Plant の各移動体と ACS 間の通信において、通信遅延を疑似的に発生させることができる。通信遅延は、以下の 2 種類存在し、それぞれ VTPParam.csv にて通信遅延の秒数を設定することができる。

- VTP Plant → ACS の通信方向の送信遅延（図 ３．６．３－４の②、④-1、⑤が該当）
- ACS → VTP Plant の通信方向の受信遅延（図 ３．６．３－４の③、④-2 が該当）

３．６．３．４ 仮想テスト

VTP Plantではその事象が発生した場合の疑似テストを行う。詳細は、可視化機能の「画面アクション」、「画面表示機能」、及び「動画再生ファイル出力」を参照のこと。

図 ３．６．３－５ 無人機システムの運用状態一覧

状態	内容	例
定常	無人機システムが行うべき任務が行われている状態	移動体トラフィック表示、生産性評価指標表示、衝突検知、実機表示等
非定常	想定内であるが歓迎されない事象が発生していること。無人機システムは、予め規定された手順でその事象を取り除き、定常状態に戻すことができる。	エネルギーチャージ、未知物体検知等
異常	予見できる想定外の事象が発生していること。定常状態への回復手順が定められている。	突発的故障発生等
例外	予見していない想定の範囲外の事象が発生していること。定常状態への回復手順が不明。	（範囲外）

３．６．４ UI

可視化機能の要求を以下に示す。

- メイン画面は、研究者が着目するエリアを拡大表示し、エージェントの応答を可視化できること。
- 操作では、システム開始・終了、操業開始・終了、各種疑似障害や人誤侵入等の操作、自己・相手エージェント表示の切り替えができること。
- 統計情報は、任務の遂行状況の表示ができること。

３．６．４．１ 画面レイアウト

VTP Plantの画面レイアウトは以下のとおり、3つの画面エリアから構成される。VTP Plantの各画面エリアについては以下のとおり。

（注）現状、適宜、機能を拡張しているため、統計情報表示エリアの下部にもオペレータ操作エリアの一部が表示されるレイアウトとなっている。

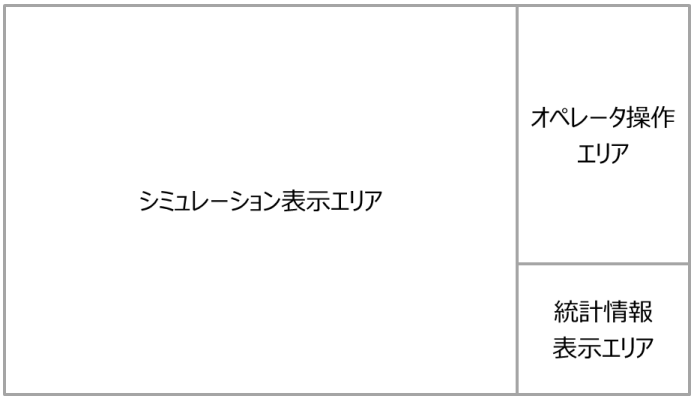

図 ３．６．４－１ VTP Plant の画面レイアウト

表 ３．６．４－１ VTP Plant の画面エリア

画面エリア名	説明
シミュレーション表示エリア	Physics.csv の NODE と LINE で定義された節点と線をもとにマップを表示し、MB で定義された移動体の走行状況を表示する。
オペレータ操作エリア	オペレータがシミュレーション表示エリアの移動体に影響を与えるための UI（テキスト入力やボタン押下など）を提供する。
統計情報表示エリア	シミュレーションの統計情報を表示する。

３．６．４．２ 画面イメージ

VTP Plant の GUI は、3D 化及び各種画面アクションに対応した。以下に新旧 GUI を示す。

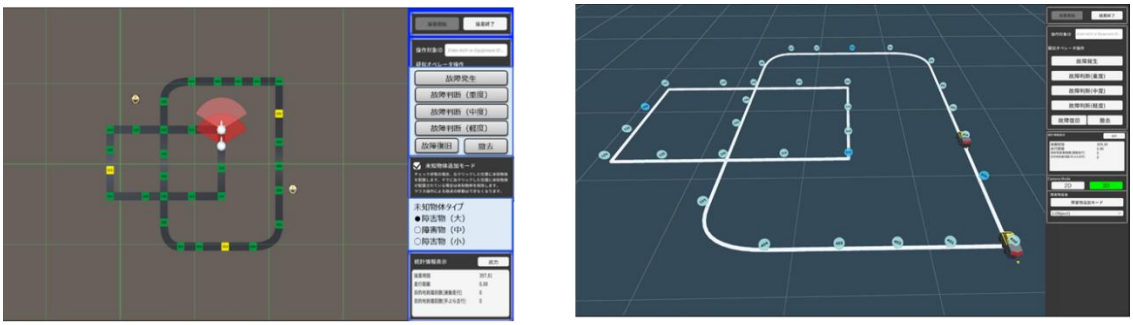

図　３．６．４－２　VTP Plant GUI 新旧比較

VTP Plant の画面イメージは以下のとおり。

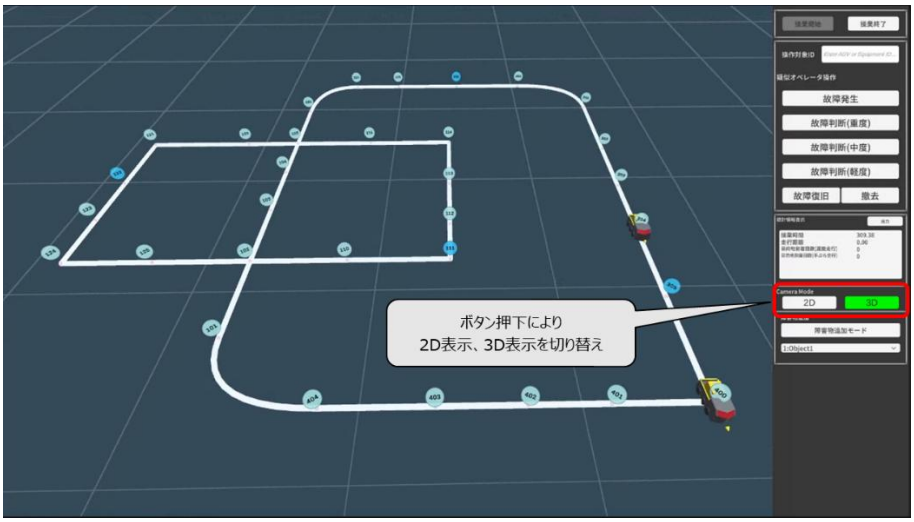

図　３．６．４－３　VTP Plant 画面イメージ(3D)

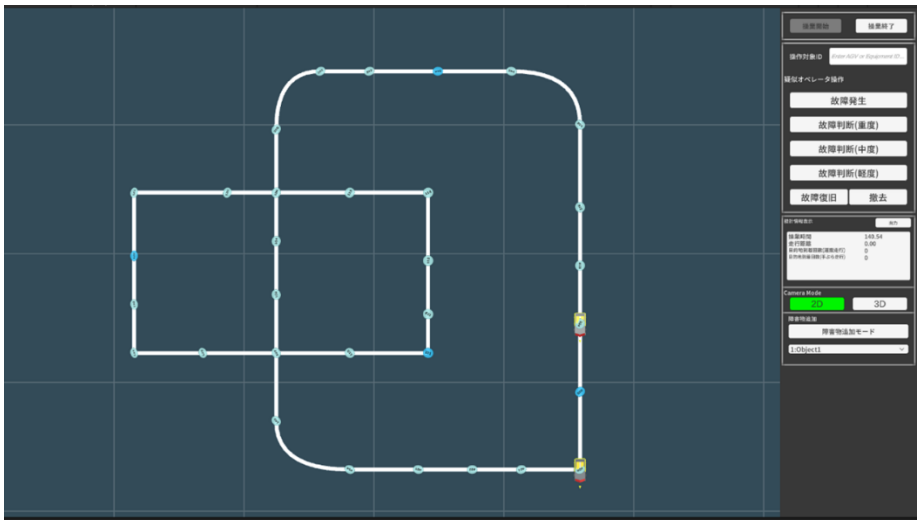

図　３．６．４－４　VTP Plant 画面イメージ(2D)

VTP Plant の障害物の追加モード時の画面イメージは以下のとおり。 2D 表示に切り替わり、プルダウンで選択した障害物の種類に応じた障害物を右クリックによりシミュレーション上に追加できる。

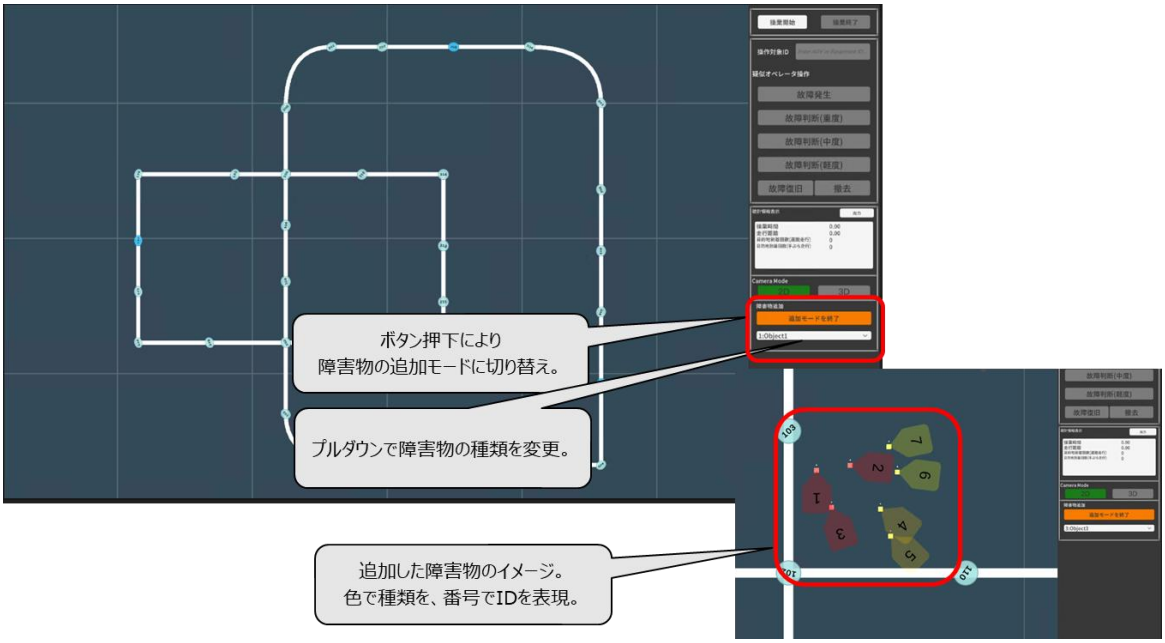

図 ３．６．４－５ VTP Plant の画面イメージ（障害物追加モード）

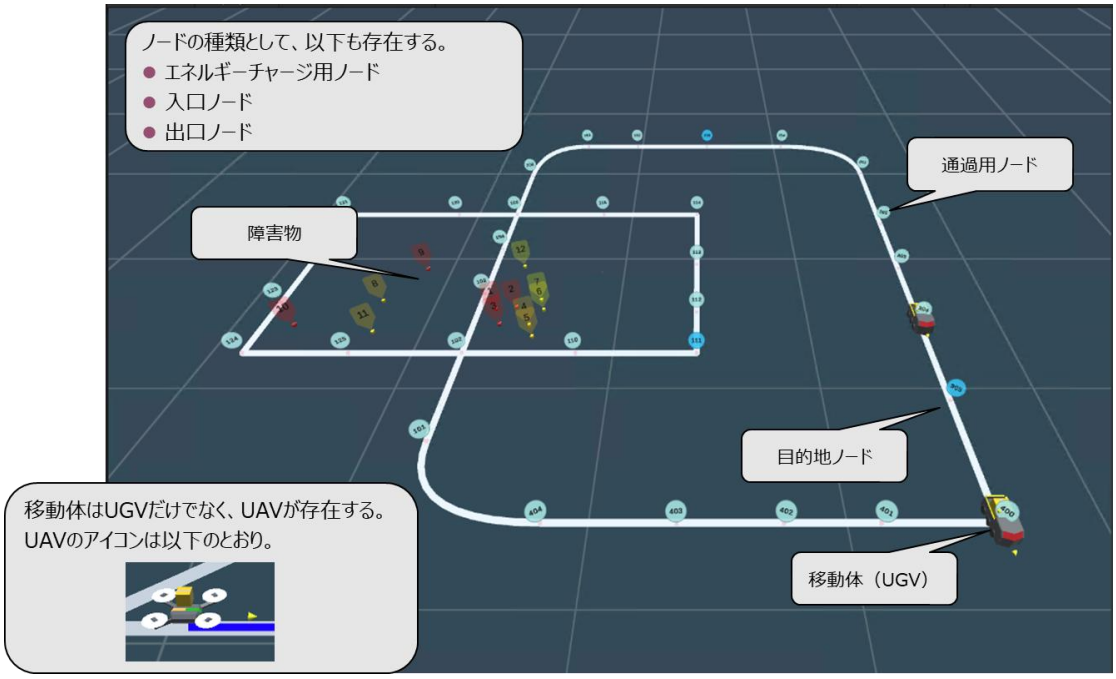

図 ３．６．４－６ VTP Plant に表示されるアイコン

３．６．４．３ 画面アクション

VTP Plantの画面アクションを示す。

表 ３．６．４-２　画面アクション一覧

No	画面アクション	処理内容
1	操業開始ボタン押下	VTP Plantのサービスを開始する。
2	操業終了ボタン押下	VTP Plantのサービスを終了する。
3	故障発生ボタン押下	移動体を故障状態にする（急停止させる）。
4	故障判断（重度）ボタン押下	移動体を重度故障状態と判断し、強制撤去（シミュレーション上から破棄）する。
5	故障判断（中度）ボタン押下	移動体を中度故障状態と判断し、PATH、PMTをクリアする。
6	故障判断（軽度）ボタン押下	移動体を軽度故障状態と判断し、PATH、PMTを保持したままとする。
7	故障復旧ボタン押下	移動体を故障状態から復旧させる。 中度の場合はアイドル状態に、軽度の場合は元の状態からシミュレーションを再開する。
8	撤去ボタン押下	移動体を撤去（シミュレーション上から破棄）する。
9	出力ボタン押下	シミュレーションの統計情報ファイルを出力する。
10	2Dボタン/3Dボタン押下	シミュレーション表示エリアの2D表示、3D表示を切り替える。

No	画面アクション	処理内容
11	障害物追加モードボタン押下	障害物追加モードのON/OFFを切り替える。
12	シミュレーション表示エリアで右クリック（障害物追加モード時のみ）	クリック位置にプルダウンで指定した種類の障害物を配置する。
13	シミュレーション表示エリアで障害物上でホイールクリック	クリック位置に存在する障害物を削除する。
14	固定カメラセンサ表示のラジオボタンにチェック	対象の固定カメラのセンサ検知範囲を可視化する。
15	固定カメラセンサ表示のカメラの位置へボタン押下	対象の固定カメラのセンサが向いている方向の真後ろに視点を移動する。

３．６．４．４ 画面表示機能

（１） 統計情報表示

（ア）画面表示

統計情報として画面表示する項目は以下のとおり。

表 ３．６．４-３ 統計情報の項目一覧

項目名	内容
経過時間	シミュレーション内で経過した時間を表示する。 シミュレーションを加速した場合でも変化しない。
走行距離	シミュレーション内の全エージェントの走行距離を表示する。
目的地到着回数	シミュレーション内の全エージェントの目的地に到着した回数を表示する。

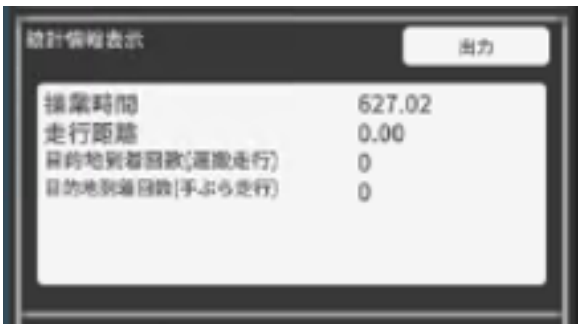

図 ３．６．４-７統計情報の画面項目イメージ

（イ）ログ出力

統計情報の詳細はプロセス終了時に出力されるStatistics.csvを参照する。Statistics.csvに出力される項目は以下のとおり。

表 ３．６．４-４ Statistics.csv の出力項目一覧

項目	内容
実作業時間	目的地での作業した時間（ノード単位に集計）
有償走行時間	荷物を持った状態で走行した時間
無償走行時間	荷物を持たない状態で走行した時間（旧称：手ぶら走行時間）
トラブル時間	故障状態の時間
アイドル時間	次の目的地の指示待ちや PMT 待ちの時間（旧称：仕事待ち時間）
走行距離	エージェントが走行した距離
有償走行による到着回数	荷物を持った状態で目的地に到着した回数
無償走行による到着回数	荷物を持たない状態で目的地に到着した回数

（２） PMT 重複検出（衝突予測検出）

各移動体の PMT が重複する場合、衝突する可能性があるため、各移動体の PMT が重複していないかを一定間隔でチェックする。PMT の重複を検出した場合は、下図のように対象の移動体に「！」マークを表示し、対象のノードを赤枠で囲んで表示する。本機能は ON/OFF の切り替えが可能。

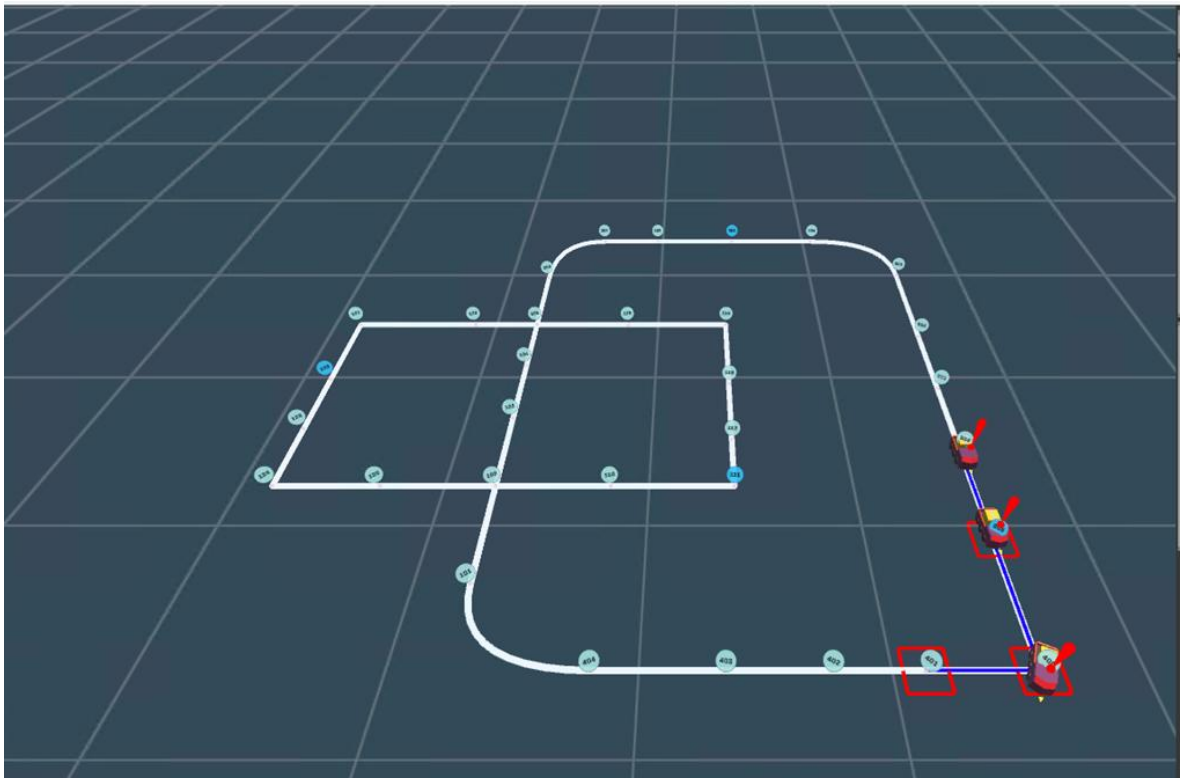

図 ３．６．４－８ PMT 重複の検出時の画面イメージ

（３） センサ反応

センサとは、カメラ、LiDARなどを指す。センサは、Physics.csvにて「PSENSOR」のモデル名で定義する。検知エリアは、図 ３．６．４－９に示すように半径と中心角で表現する。センシング間隔、送信間隔、送信タイプでACSに送信するデータを制御する。

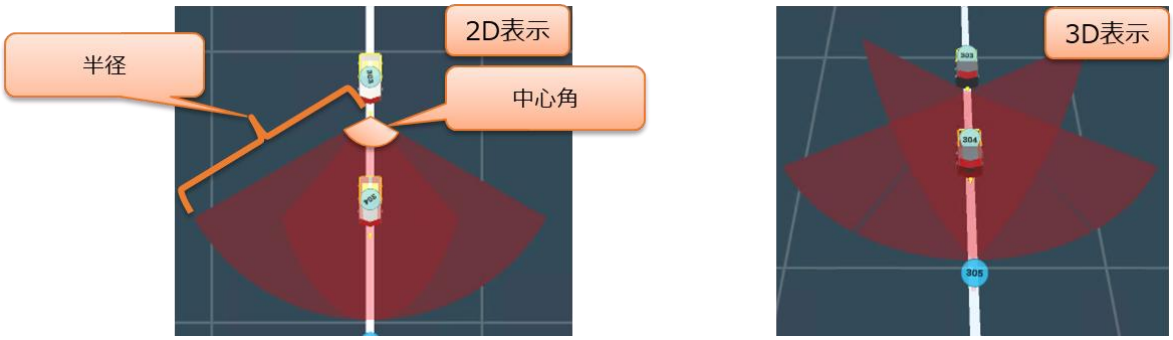

図 ３．６．４－９ センサの検知エリアイメージ

センサは、いかなる状態（例えば、走行中、充電中、アイドル中など）においても物体を検知するものとする。センサの検知対象となる物体を以下の表に示す。

表　３．６．４－５　センサ検知対象物

No	名称	概要
1	未知物体	中央プレイヤの ACS が管理外である未知の物体
2	仲間エージェント	同一プレイヤの ACS の管理下にある移動体
3	競合エージェント	競合プレイヤの ACS の管理下にある移動体

センサ検知した場合の挙動は、以下の表のとおり。Physics.csvの設定によって挙動を制御せず、移動体ごとにプログラムを個別に作成して挙動を制御する。

表　３．６．４－６　センサ検知時の挙動

No	移動体	センサー範囲	センサ検知時の挙動
1	UGV	近距離	急停止して、センサが検知しなくなるまで、PATH、PMT は保持したまま、その場で待機する。将来的に実装予定。
2	UGV	遠距離	センサの検知情報を ACS に通知するのみで、走行には影響させない。
3	UAV	遠距離	巡回の任務を与えられている場合、センサの検知情報を ACS に通知するのみで、飛行には影響させない。 巡回/追跡の任務を与えられている場合、センサの検知情報を ACS に通知し、その後、マップの NODE や LINE、PATH、PMT を無視して、部外者の上空を飛行し続ける。

センサ検知した場合にのみ、センサの検知状況を ACS に通知する。ACS に連携されるセンサ検知状況のデータイメージは以下のとおり。

表　３．６．４－７　センサ検知状況のデータイメージ

凡例	移動体　センサ検知エリア　検知物体　※センシング間隔を1秒、送信間隔を5秒としている			
例題内容	例1:検知物体なし	例2 検知物体あり 検知物体は移動しない	例3 検知物体あり 検知物体は移動する （3秒後に左に移動）	例4 検知物体あり 検知物体は移動する （2秒後に右、3秒後にさらに右に移動）
イメージ図	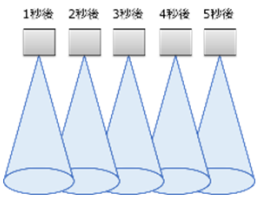	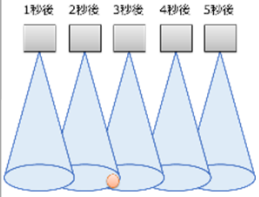	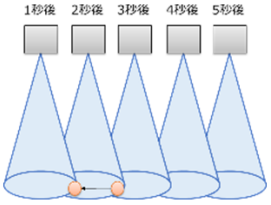	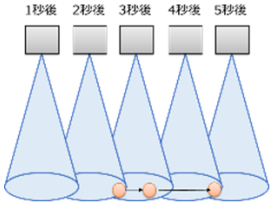
送信タイプ オールの データイメージ	検知データは連携しない	10:00:02 座標X 10:00:03 座標X	10:00:03 座標X	10:00:02 座標X 10:00:03 座標Y 10:00:04 座標Z 10:00:05 座標Z
送信タイプ サマリの データイメージ	検知データは連携しない	10:00:03 座標X	10:00:03 座標X	10:00:05 座標Z

（４） 固定カメラ

固定カメラは、定点位置から移動せずにセンサ検知する機能である。主に、フィールド上空に設置して、フィールド全体の状況を把握するような使途を想定している。
固定カメラの検知エリアは広範囲にわたり、センサ検知が高頻度となることから、通常のセンサのように対象物を検知した場合に赤色の検知エリアを表示させるとシミュレーションの状況把握を阻害する恐れがある。そのため、センサ検知時は赤色の検知エリアは表示せず、ACS への検知データの送信のみを行う。
固定カメラの検知エリアを確認するには、固定カメラセンサ表示にて、検知エリアを表示させたい固定カメラを選択（左下図）する。これにより、黄色の検知エリアが表示されるとともに、検知エリア内に含まれるノードが赤枠でマークされる（中央下図）。また、「カメラの位置へ」ボタンを押下すると、固定カメラの向きを真後ろから見た視点に切り替えることもできる(右下図)。

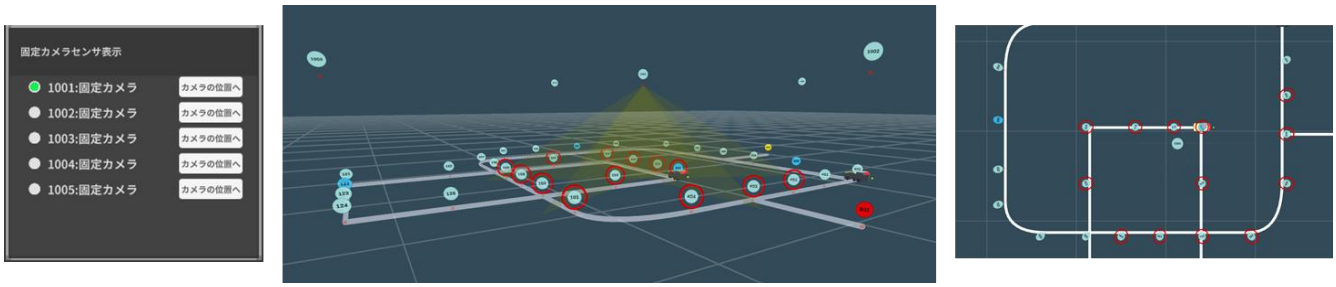

図 ３．６．４－１０　固定カメラセンサ表示の画面イメージ

３．６．５ 動画再生ファイル出力

VTP Plantでシミュレーションした移動体の動きを動画再生するためのファイルを出力する。
出力される動画再生ファイルは移動体用と障害物用の2種類がある。

- 移動体用：Replay_YYYYMMDDHHMMSS.csv
- 障害物用：ReplayObstacle_YYYYMMDDHHMMSS.csv

動画再生ファイルは、動画再生モード（VTP Param.csvの起動モードを「1」に設定した状態でプロセスを起動）で使用する。VTPParam.csvにて、動画再生ファイルの出力要否、記録間隔、ファイル出力間隔を設定することができる。

表 ３．６．５－１ 移動体用動画再生ファイル出力情報一覧

No	種類	出力情報
1	演算諸元	フレームレート、フレーム番号、経過秒数
2	移動体識別	移動体 ID
3	位置	ノード ID 、X 座標、Y 座標、Z 座標
4	運動	機首方向角、速度
5	状態	荷物有無、状態

※表中の赤文字の項目は、実機システムとの連携時には、仮想機とは別に実機の情報も保持する。

図 ３．６．５－１障害物用動画再生ファイル出力情報一覧

No	種類	出力情報
1	演算諸元	フレーム番号、経過秒数
2	障害物識別	オブジェクト ID、オブジェクトタイプ、 オブジェクトサブタイプ
3	位置	X 座標、Y 座標、Z 座標
4	有無	存在確率

動画再生モード（VTP Param.csv の起動モードを「1」に設定した状態でプロセスを起動）で動画再生ファイルを使用した場合の画面イメージは以下のとおり。

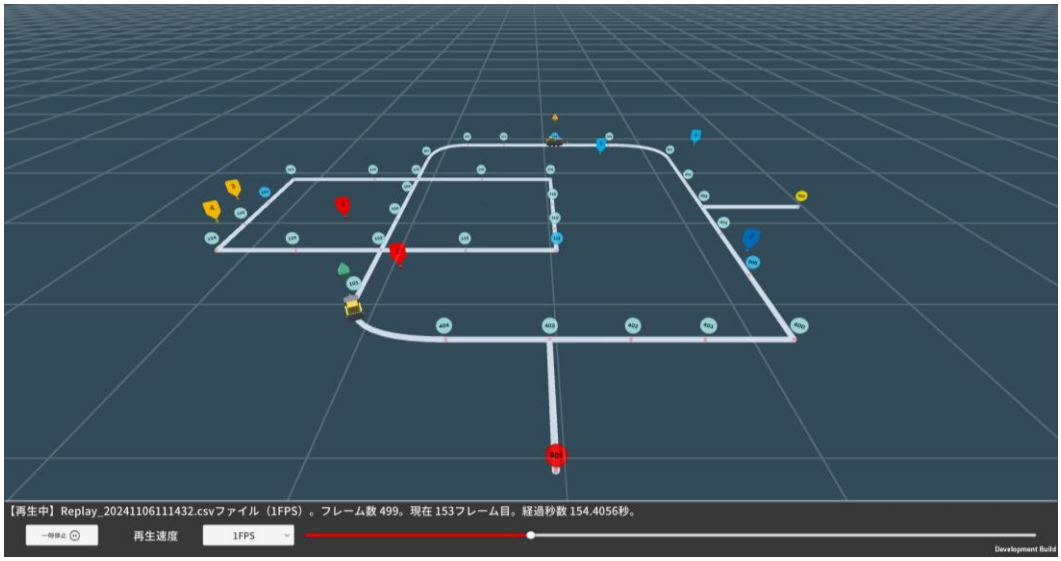

図 ３．６．５－２ 動画再生モードの画面イメージ

３．６．６ 高度化２「工場作業員誤侵入危険回避」対応

（１） 突発事象対応

VTP Plant は以下の画面 UI を操作することで、各移動体に故障を発生させることができる。

（ア）状態遷移

画面 UI による移動体の状態遷移図は下図のとおり。

状態遷移図に表現されていないボタン押下（例えば、トラブル状態での故障発生ボタン押下など）は無効とする。故障の種類（通信エラー、センサ不具合、エンジントラブルなど）の指定は不可とする。また、複数の故障が同時発生する場合についても考慮しない。それらをまとめて、故障の重度、中度、軽度の分類で管理する。

図 ３．６．６－１故障関連の画面 UI

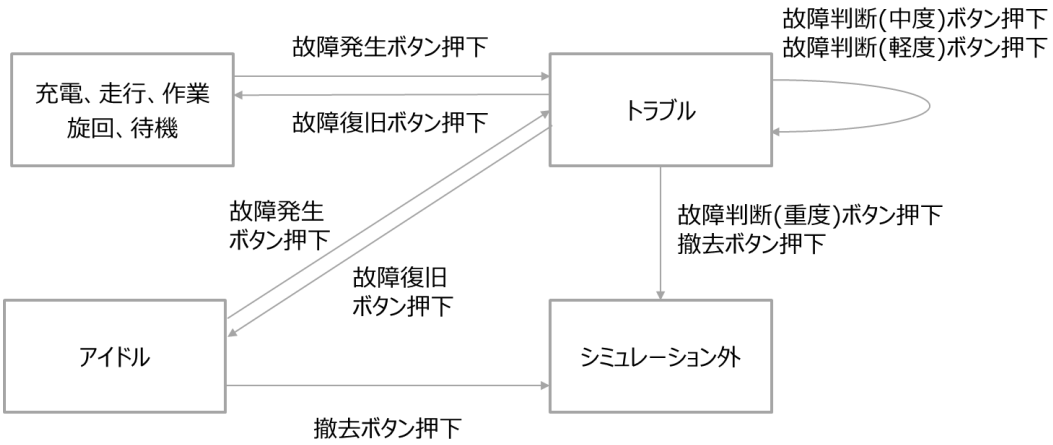

図 ３．６．６－２故障関連の状態遷移

（イ）ボタン押下時の挙動

各ボタン押下時の挙動は以下の表のとおり。UAV と UGV の挙動は同一とする。

図　３．６．６－３　故障関連のボタン押下時の挙動

No	ボタン	ボタン押下時の挙動
1	故障発生	急停止して、その場で待機する。 旋回中、作業中、充電中の場合も、それぞれの処理を中断する。
2	故障判断（重度）	復旧不可のため、シミュレーション上から削除する（強制撤去）（※1）。
3	故障判断（中度）	PATH、PMT をクリアし、その場での待機を継続する。 充電中、作業中の場合は、それぞれの処理を終了（※2）したものとして扱う。
4	故障判断（軽度）	PATH、PMT を保持したまま、その場での待機を継続する。 旋回中、充電中、作業中の場合は、それぞれの処理を中断（※2）させる。
5	故障復旧	「故障判断（中度）」の場合、アイドル状態となり、次のタスクの受信待ちとなる。 「故障判断（軽度）」の場合、その場から走行を再開する。旋回中、充電中、作業中の場合は、それぞれ中断した残りの処理を継続する。
6	撤去	シミュレーション上から削除する（※1）。

※1　撤去（強制撤去含む）の対象となった移動体はシミュレーション上から削除されるが、その後、修理してシミュレーション上に復活する場合もありえる。

※2　処理の終了と中断について補足する。例えば、作業時間 10 分のうち、3 分だけ作業したタイミングで「故障発生」ボタンが押下された場合を考える。その後、「故障判断（中度）」ボタンが押下された場合は、残り 7 分の作業は実施しない。その後、「故障判断（軽度）」ボタンが押下された場合は、残り 7 分の作業は実施する。なお、旋回には終了は存在しないため、常に中断となる。

（ウ）故障復旧

故障復旧した場合の移動体の位置について補足する。

ノード 101、102、103、104 の順で移動体が走行していて、102 と 103 の間で故障発生ボタンを押下し、故障判断（中度）または故障判断（軽度）ボタンを押下して、故障復旧ボタンが押下された場合、復旧後の移動体の位置は、故障判断（中度）の場合はオレンジ色のアイコン、故障判断（軽度）の場合は青色のアイコンの位置となる。

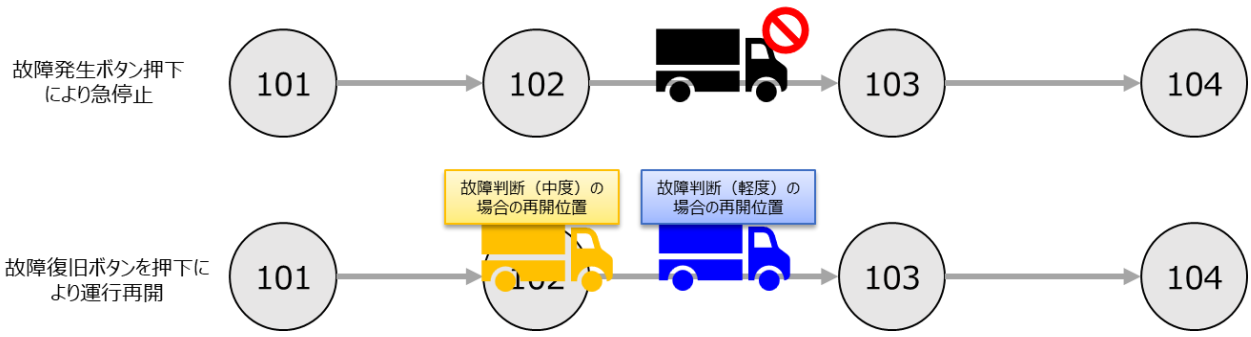

図　３．６．６－４故障復旧後の移動体の位置

３．６．７ 高度化３「捜索・救難UAV/UGV混在3D化対応」

UAV をシミュレーションに追加するにあたって、シミュレーション表示エリアの 3D 化対応を実施し、立体的で奥行きのある UI を実現した。

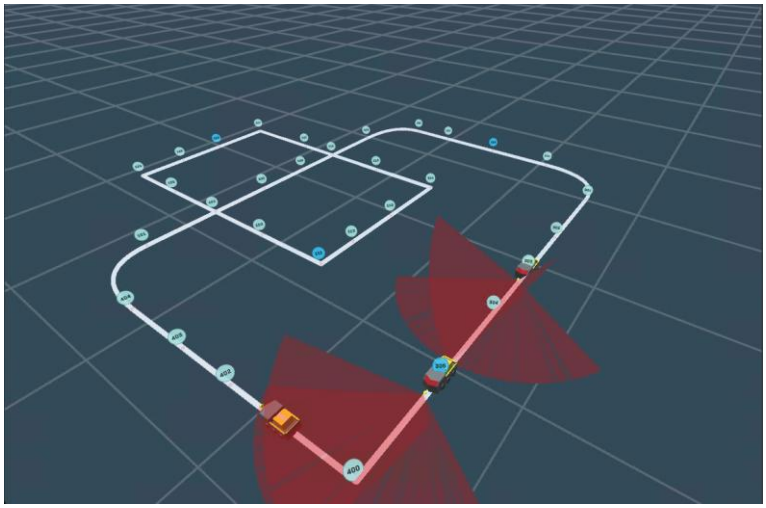

図 ３．６．７－１3D 化対応した VTP Plant のシミュレーション情報表示エリアのイメージ

空中を飛行する UAV が地上の UGV や障害物を探索するシミュレーション時のイメージを下図に示す。

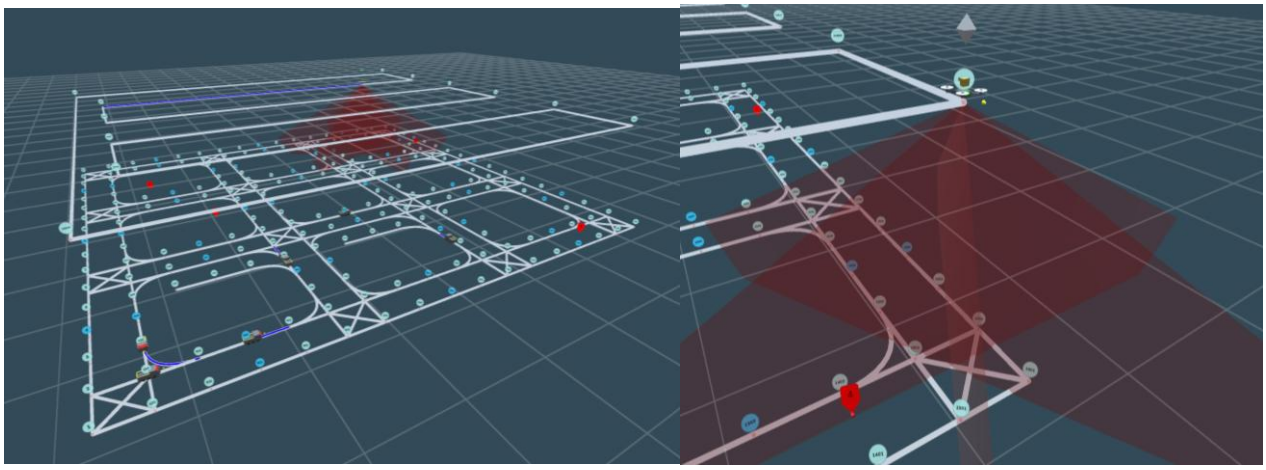

図 ３．６．７－２ UGV/UAV シミュレーション時の VTP Plant のシミュレーション情報表示エリアのイメージ

３．７ 実施項目⑥実機テスト環境の構築と試験実施

３．７．１ 成果概要

結論：本実証により、RCT-OODA群制御AIアーキテクチャによる「OODAループ自律化機能」が、実環境下の複数シナリオにおいて安定して動作し、AIによる状況認識・判断・行動の統合制御が実機において成立することを確認した(表 ３．７．１－１参照)。
これにより、実機適用に向けた信頼性と実用性の技術的基盤が確立された。

試験概要：
試験場所：日本大学生産工学部 振動実験室（図 ３．７．１－１参照）
評価対象：RCT-OODA群制御AIアーキテクチャ(MAARC + 無人機システム)
使用機材：無人搬送機（Kachaka）、遠隔監視システム（HATS）

実証目的：AIによるOODAループ(観測・状況認識・意思決定・行動実行)の全体を、MAARCのCPS環境下で自律化し、実際の物理空間で動作するかを検証する。

手法：遠隔監視制御システム（HATS）および無人搬送機（kachaka）を用いた実機システムに、MAARCを接続し、Sim2Realギャップに対する安全性を考慮したCPSアーキテクチャを構築した。VTP内に構成されるリアルタイムデジタルツイン経由で、AIが実機の応答を意思決定に反映させる制御フローを実装した。さらに、MAARCと実機システム間を接続するSwarm IF（スウォーム・インターフェース）を詳細設計・実装し、通信プロトコルや連携仕様を整備した。

総括：本実証により、RCT-OODA群制御AIアーキテクチャが、複数移動体の交通管制・動的リスク回避を実現可能であり、意思決定と群制御の自律化に対応できることが確認された。これにより、マルチエージェントAIの基盤技術としてのMAARCアーキテクチャの信頼性・応用性が実証された。今後は、複雑環境・多数機・異種エージェント混在環境への拡張へと発展可能である。

表 ３．７．１－１ 実機テスト想定シナリオと結果概要

#	想定シナリオ名称	結果概要	備考
0	通常時（比較用）	動的リスクが存在しない場合には最短経路を生成した。	合格
1	定点カメラ物体検知・リスク迂回	定点カメラが物体検知しリスク判定→リスク回避する経路を生成・再生成した。	合格
2	移動体カメラ物体検知・リスク迂回	移動体が物体検知しリスク判定し、他の移動体がリスク回避する経路を生成・再生成した(図 ３．７．１－２参照)。	合格(図示)
3	渋滞迂回	移動体2台が渋滞し、他の3台の移動体が渋滞回避して迂回する経路を生成した。	合格
4	T字合流制御	T字路で左右から移動体2台・3台が合流地点に向かい、ACSの指示に従い待合氏、1台ずつ通過した。	合格
5	長距離テスト	システムの安定性、可用性の簡易評価。18分程度走行し、最終的に5台中4台を撤去したが、最後の1台は全てのゴールをこなした	合格

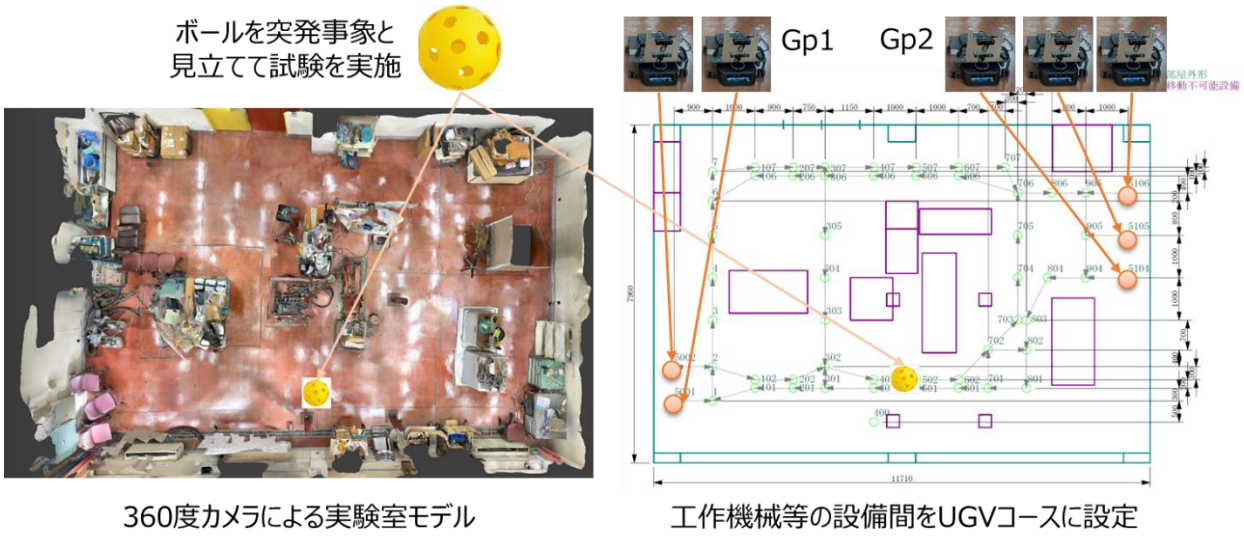

図　３．７．１－１　実機テスト試験場概要（日本大学生産工学部振動実験室）

想定シナリオ＃２　移動体カメラ物体検知・リスク迂回　ケース図示

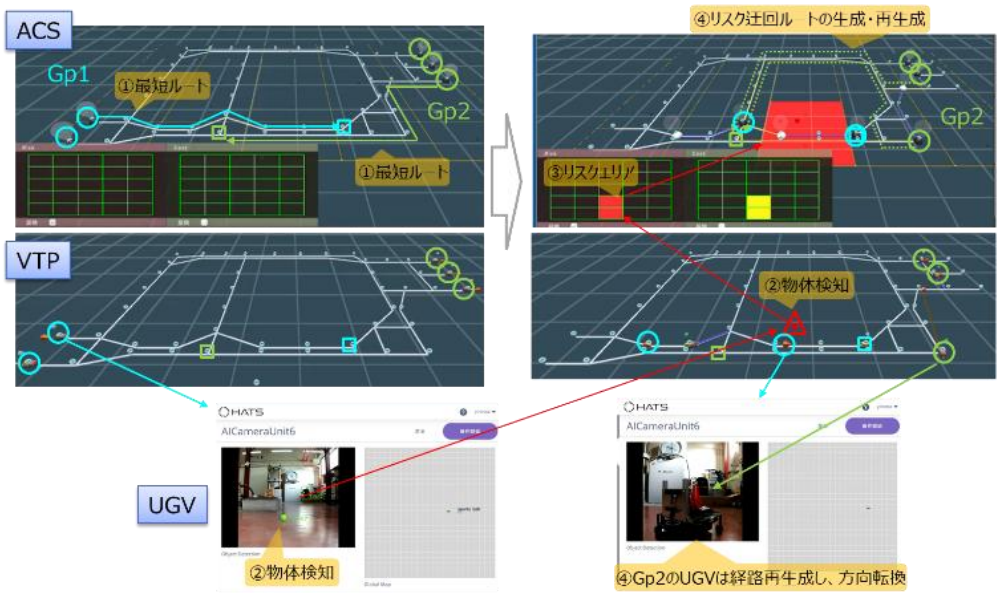

図　３．７．１－２　想定シナリオ＃２　移動体カメラ物体検知・リスク迂回　ケース図示

３．７．２ システム概要

実機テスト環境は、図 ３．７．２－１に示すように、OODA群制御AI(各ソルバ群・AI SLPF)、ACS、及びVTP Plantのサイバー側が、フィジカル側の実機システムと連接するCPS(サイバーフィジカルシステム）環境として構成される。その制御フローと送受信するデータの概要を**エラー！参照元が見つかりません。**及び**エラー！参照元が見つかりません。**に示す。

この実機 CPS テスト環境は、VTP Plant 内部の仮想世界に構築されるデジタルツインが仲介的な役割を果たしている。具体的には次のとおりである。VTP Plant 内部のデジタルツインは、運用フィールドと実機システムを仮想化したものである。このデジタルツインが、現実世界とリアルタイムに連接して、ACS の制御命令をデジタルツインの仮想移動体と同じように実機にも伝達し、その実機応答をデジタルツインにも反映する。デジタルツイン上では、仮想移動体と実機の応答が表現され、そのギャップをユーザは把握することができる。

この実機 CPS の CP 連接部分を担当するのが、スウォーム IF(モジュール名：Swarm IF)である。実機システムは、本研究では、遠隔監視制御システム「HATS」と無人機本体「kachaka」で構成される。実機システムの選定理由は、HATS が AGV 遠隔制御で実績のあること、kachaka が HATS 対応可能かつ調達、取り扱い面で優位性があることである。

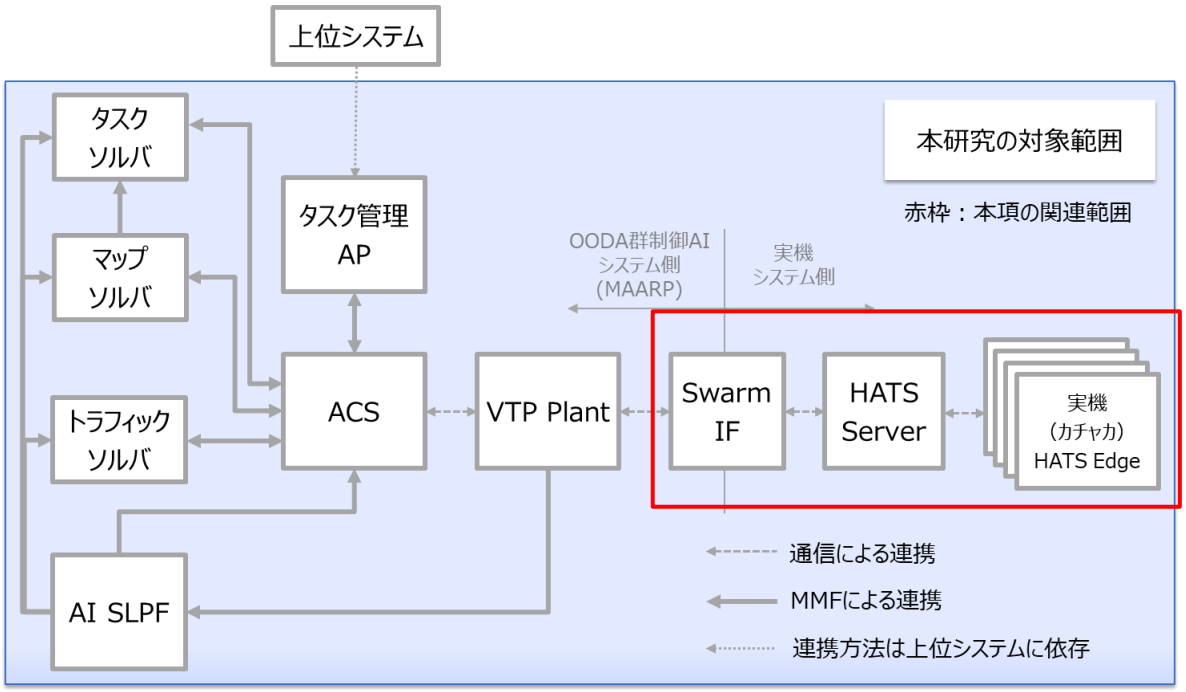

図 ３．７．２－１ OODA 群制御システムと実機システムと連接

３．７．３ CP連接（サイバー・フィジカル連接）方式

CP(サイバー・フィジカル)連接方式について説明する。

OODA 群制御 AI システムと実機システムは、マップや空間情報の表現データ形式、及び制御データ形式が異なることを、前提として設計している。その設計目的は、OODA 群制御 AI システムの汎用性を高めることである。そのため、サイバーとフィジカル側の両システムを連携するための機能が必要となる。その CP 連接を担う機能がスウォーム IF である。

スウォーム IF は、下図に示すように、データ変換とデータ通信の機能を担う。これらの機能は、Swarm IF モジュールに実装され、制御命令と応答情報を仲介し、 OODA 群制御システムと実機システムを連接する。

データ変換は次の通り。Map を定義する Physics.csv に、節点 ID 番号と座標値が定義されている。データ変換は、ID・座標値の変換だけでなく、要すれば MAARP 世界と無人機システム世界の座標系変換も行う。実施項目③ロジックソルバの「(2)トラフィックソルバ＞(エ)実機移動体への要求」も併せて参照のこと。

スウォーム IF の設計については、次項に示す。

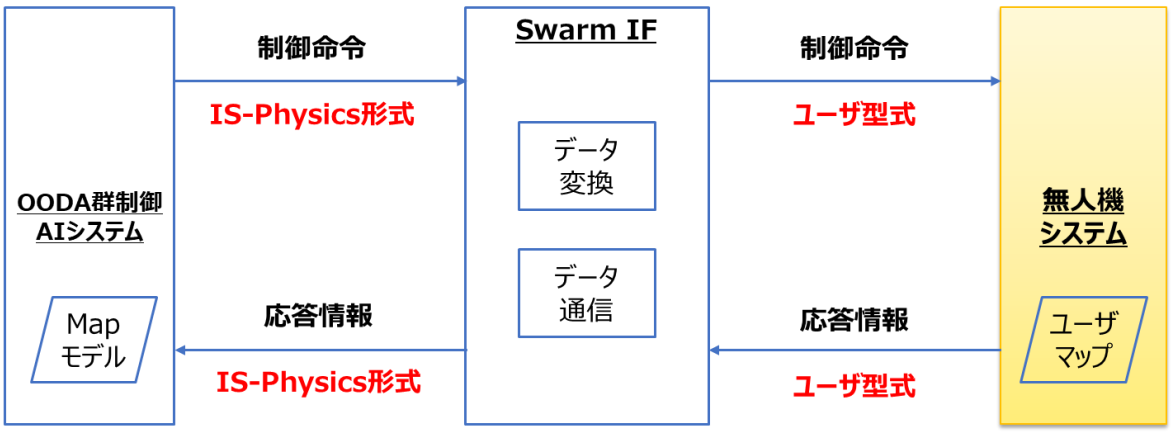

図 ３．７．３－１スウォーム IF の概要

３．７．４ スウォームIF

（１） 概要

スウォーム IF のデータ変換とデータ送受信機能を担うのが Swarm IF モジュールである。

Swarm IF は、図 X に示すように、OODA 群制御 AI システムが生成した制御命令（PATH、PMT）を仲介して実機システムへ経路及び移動許可情報として伝達し、実機システムが生成した状態情報を仲介して OODA 群制御システムへ応答情報（STATUS）として伝達する。

データ変換では、OODA 群制御 AI システムのマップモデルとユーザーのマップモデルに従って、双方のデータを変換する。マップ情報の変換方法の設定は、IS-Physics モデル規約に定義する。制御情報（命令・応答）の変換は、Swarm IF に実装する。データ変換詳細は、次項に示す。

データ通信は、多機種・多機数に対応できるように汎用性が高い「Zenoh(https://zenoh.io/)」を採用した方式とした。詳細は、後述する。

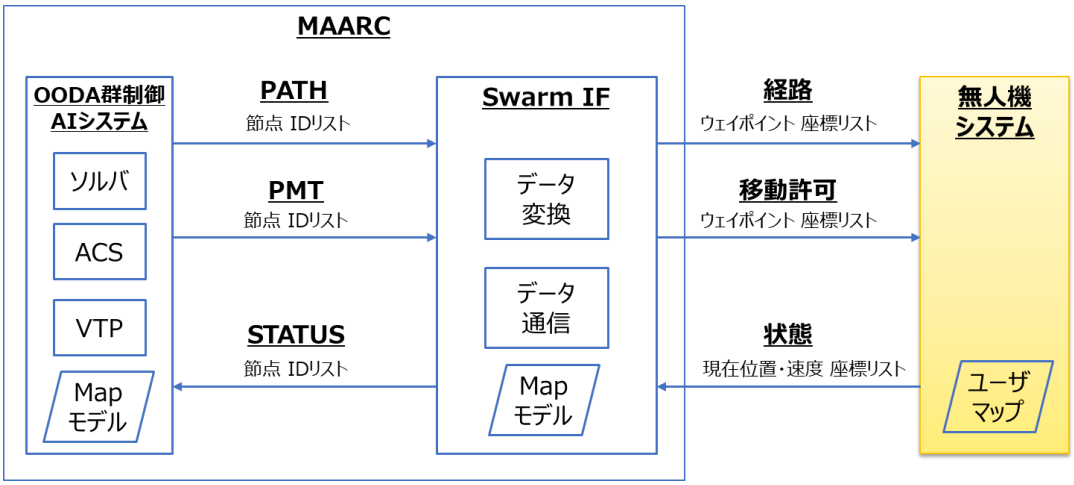

図 ３．７．４－１ スウォーム IF のデータフロー

（２） データ変換

データ変換では、OODA 群制御 AI システムのマップモデルとユーザーのマップモデルに従って、双方のデータを変換する。

表 ３．７．４－１スウォーム IF のデータ変換

制御情報	OODA群制御AIシステム	方向	実機システム（例）
制御命令：経路	PATH（節点ID リスト）	→	ウェイポイント（座標値 リスト）
制御命令：移動許可	PMT（節点ID リスト）	→	ウェイポイント（座標値 リスト）
応答情報：状態	STATUS（節点ID リスト）	←	状態：座標値、速度、時刻等

表 ３．７．４－２スウォーム IF の座標変換

空間表現情報	OODA群制御AIシステム	方向	実機システム（例）
座標系	右手系	← →	（ユーザ定義による）
水平面（地面）	ｘｙ平面（ｚ=0）	← →	（ユーザ定義による）
高さ方向	＋ｚ軸方向	← →	（ユーザ定義による）

（３） 通信方式

データ通信は、多機種・多機数に対応できるように汎用性が高い「Zenoh(https://zenoh.io/)」を採用した方式とした。採用理由を以下に示す。

スケーラブル

Zenoh プロトコルとその実装は分散化されており、スケールアウトとスケールダウンが可能です。Zenoh は、アプリケーションをインターネット規模で展開できるスケーラブルなルーティング インフラストラクチャを通じてスケールアウトを提供します。

低レイテンシ

Zenoh はレイテンシが非常に低いため、オーバーヘッドと応答時間が非常に低いことが求められるアプリケーションに適しています。

低電力ネットワーク

Zenoh は、LPWAN や LowPAN などの非常に制約の厳しいトランスポート上で動作するよう設計されています。使用可能な帯域幅を最大化するために、Zenoh は OSI レイヤー 2 上で動作し、ワイヤ オーバーヘッドは 4 バイトと最小限に抑えられています。

高スループット

Zenoh は非常に高いスループットを実現し、バッチ処理 API を通じて既製のパフォーマンスをさらに向上させることができます

表 ３．７．４－３対象としている通信レイヤ

レイヤ	レイヤ名称	概要	Swarm IF (※1)	Zenoh (※2)
7	アプリケーション層 (Application Layer)	ユーザーやアプリケーションが直接やり取りするインターフェースを提供する。例として、HTTPやFTPなどが該当。	○	○
6	プレゼンテーション層 (Presentation Layer)	データのフォーマット変換や暗号化・復号、圧縮などを行い、アプリケーションが理解できる形式に変換する。	○	○
5	セッション層 (Session Layer)	通信セッションを確立、管理、終了させる役割を持つ。	○	○
4	トランスポート層 (Transport Layer)	エンドツーエンドの通信を確立し、データの分割、エラー検出、信頼性を提供する。		○
3	ネットワーク層 (Network Layer)	データが異なるネットワークを経由して送信される際にルーティングやアドレッシングを担当する。		○
2	データリンク層 (Data Link Layer)	隣接するノード間でのデータ伝送を行い、エラー検出やフレーミングを処理する。		
1	物理層 (Physical Layer)	データをビットとして物理的な伝送媒体で送受信する。		

※1: Swarm IF ソフトウェア内で明示的に操作している層。
※2: Zenoh ライブラリにて明示的に操作が可能な層。

３．７．５ 実施システムの最終構成

実機システムの最終構成を示す。調達、動作検証、構築過程は後述する。

（１） 実機システム構成の全体像

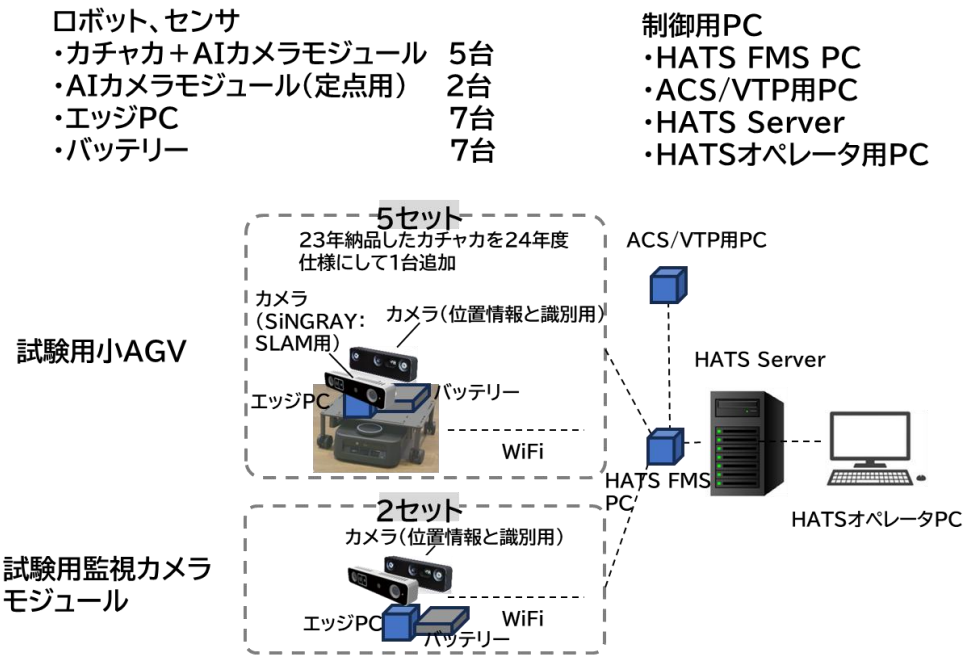

図 ３．７．５－１ 実機システム構成

（２） 主要構成要素の仕様

（ア）カチャカ

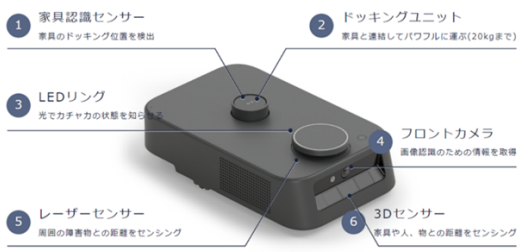

項目	仕様概要
外形寸法	幅240 mm x 奥行387 mm x 高さ124 mm
質量	10.0 kg
使用電池	充電式リチウムイオン電池
定格電圧	DC25.2 V
移動速度	最速800 mm/秒（カチャカシェルフ搭載時：500 mm/秒）
通信	Wi-Fi
カメラ	RGBカメラ× 2
センサー	レーザーセンサー（LiDAR）× 1、 3Dセンサー（ToF）× 1、 段差センサー× 2、家具認識センサー× 1
サウンド	マイク× 4 個、スピーカー× 1 個

（イ）カチャカベース

項目	仕様概要
外形寸法	幅393×行320×141mm
質量	4.2 kg
構造部材	天板/金属（アルミ）、フレーム・パイプ/金属（銅鉄）、キャスター/樹脂、金属、エラストマー

（ウ）AI カメラ

Singray Stereo PRO（vSLAM用）

項目	仕様概要
外形寸法	116mmx25mmx18mm
質量	127g
ステレオセンサ解像度	1280×800 最大50fps / 640×400 最大60fps
ステレオセンサベースライン長	80mm
ステレオセンサFOV	150°（D）×130°（H）×74°（V）
ステレオセンサ奥行計測範囲	0.5~8.0メートル
ステレオセンサ奥行計測精度	≤3%（0.5～3.0メートル）、 ≤10%(3.0～8.0メートル）
IMU	9軸 1000Hz

OAK-D-Pro-W（物体認識用）

項目	仕様概要
FOV（対角/水平/垂直）	120° /95° /70°
解像度	12MP (4032x3040)
フォーカス	固定焦点 60 cm～∞
最大フレームレート	60 fps
ピクセルサイズ	1.55 µm x 1.55 µm
センサーサイズ	1/2.3インチ

３．７．６ 実機システムの調達と基礎動作検証

３．７．６．１ 概要

本研究におけるシステム構成に含まれる無人機の管理や制御のためのシステムHATS(オンプレ版)、及び実機テストにて利用することを想定しているHATS対応の機体 kachaka との連携を確認するためのテストを行った。

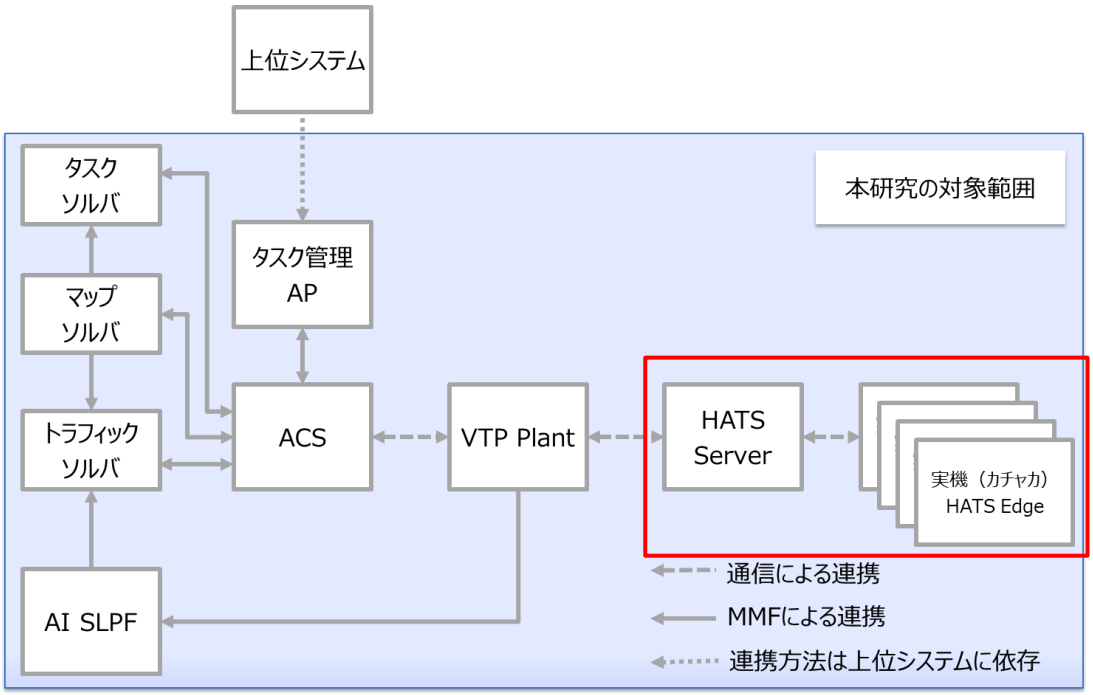

図 ３．７．６－１ 本年度の範囲

３．７．６．２ 実機無人機システム外観

今年度は、動作確認のため制御装置一式と無人機１台を調達した。無人機システムの外観、及び無人機の概要を以下に示す。

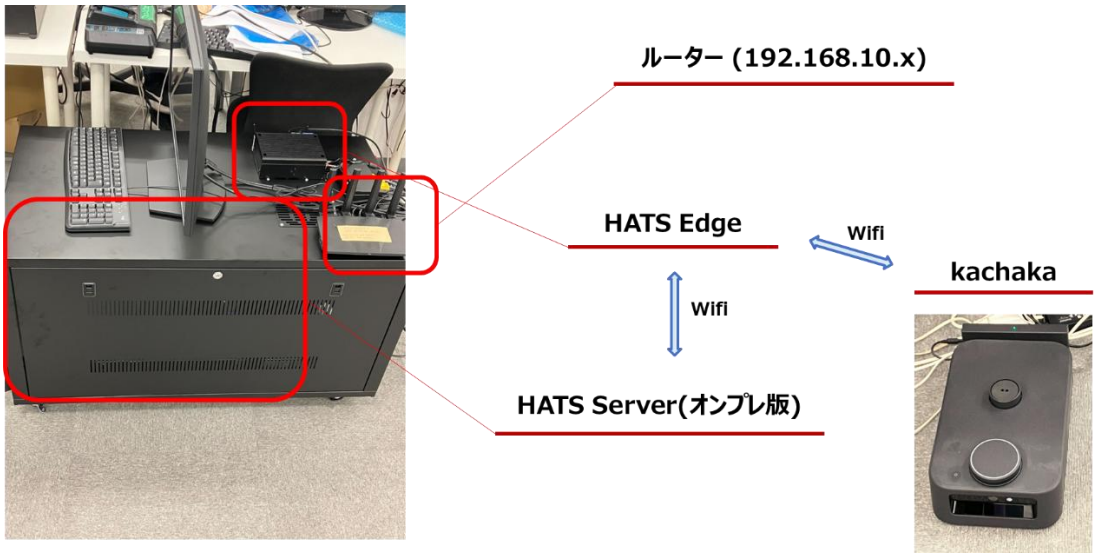

図 ３．７．６－２ 無人機システム外観

図　３．７．６－３　無人機「Kachaka」外観

出典：kachaka 公式 HP より

３．７．６．３ 動作確認試験

実機システムの動作確認試験を、表　３．７．６－１に示す試験項目について行った。

試験の結果、表　３．７．６－２に示すように合格の判定となった。試験写真を図　３．７．６－４に示す。

表　３．７．６－１　実機システム動作検証試験内容

No.	項目	概要
1	HAST・実機の連接	HATS Server(オンプレ版) および 無人機 kachaka 用の HATS Edge を用いて、機体の情報の収集や機体の制御などを HATS UI 上で操作できるかを確認する。
2	実機の機能確認	無人機 kachaka から本研究で利用する情報のやりとりを行うことができるかを確認する。確認項目を以下に示す。 ・機体の位置情報の取得 ・機体のカメラ映像の取得 ・機体の移動、旋回

表　３．７．６－２　実機システム動作検証試験内容

No.	項目	確認内容	判定
1	HAST・実機の連接	HATS UI 上で kachaka の認識に成功。 図　３．７．６－４　①参照。	合格
2	実機の機能確認	以下の 2.1～2.3 項を確認する。	合格
2.1	機体の位置情報の取得	kachaka の持つマップ情報および現在位置の確認ができた。 図　３．７．６－４　②参照。	合格
2.2	機体のカメラ映像の取得	kachaka からのカメラ映像の確認ができた。 図　３．７．６－４　②参照。	合格
2.3	機体の移動、旋回	HATS UI 上からの操作によって、kachaka の移動・旋回が可能であることが確認できた。 図　３．７．６－４　③参照。	合格

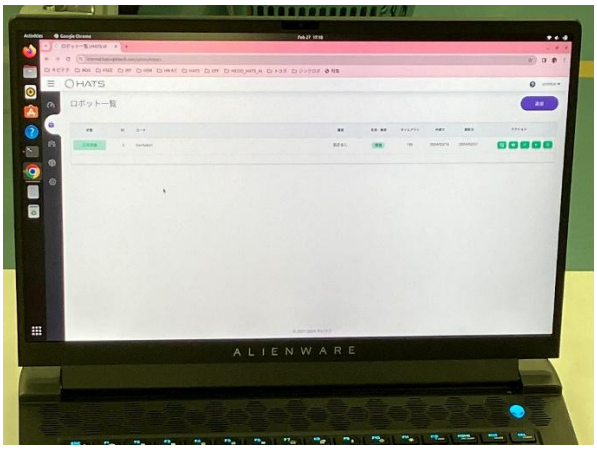

①機体認識の確認

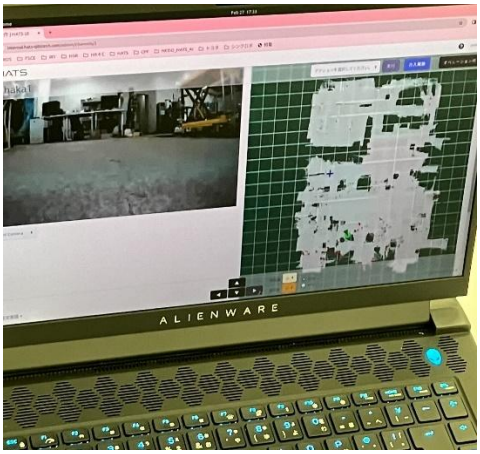

②マップ情報・位置情報取得とカメラ画像

③UI 操作による移動・旋回の確認

図　３．７．６－４　動作検証写真

３．７．７ 実機CPSテスト環境の構築

実機CPSテスト環境の構築を行った成果として、以下の内容について報告をまとめる。

- システム構成
- 通信プロトコル
- 通信フォーマット
- 開発環境の構成
- これまでの動作状況

３．７．７．１ システム構成

開発効率の観点から、HATS 側の先行試作をベースに開発する。詳細なシステム構成図を次スライド以降に示すが、整理した表を以下に示す。

表　３．７．７－１　システム構成検討経緯の整理

	ACS/VTPと HATSの接続	HATS Serverと HATS FMSの接続	通信プロトコル
先行試作	未接続	未接続	Zenoh
高度化1	接続	未接続	Zenoh
高度化2	接続	接続	Zenoh

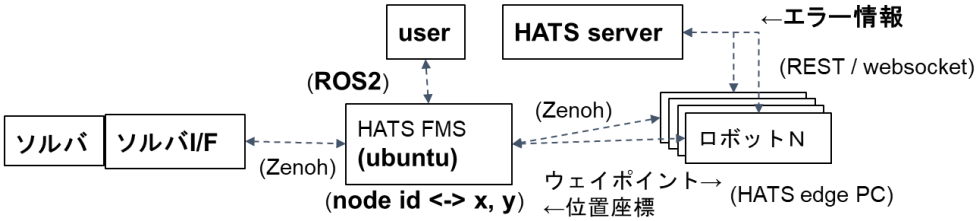

[1] 実機 CPS 連接システム構成（HATS 先行試作）

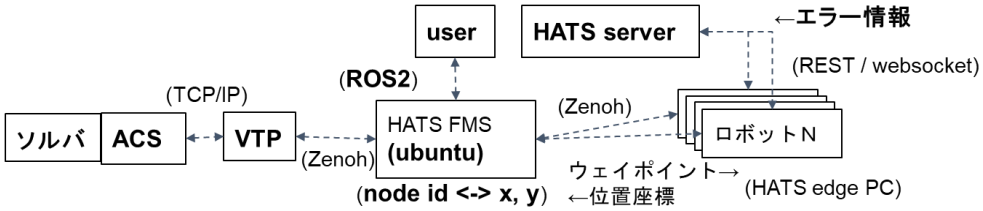

[2] 実機 CPS 連接システム構成（高度化 1）

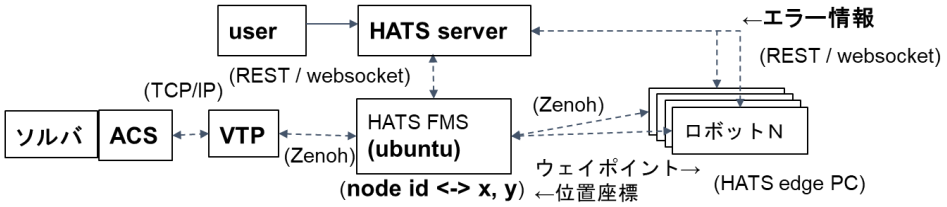

[3] 実機 CPS 連接システム構成（高度化 2）

図　３．７．７－１システム構成構築プロセス

３．７．７．２ 通信プロトコル

キビテク社での実績から Zenoh を選定した。セキュリティの観点から TLS を用いることとした。以下に別方式との比較を示す。文献調査により、スループットが一番良い Zenoh（下図の紫と橙の線）を採用する。

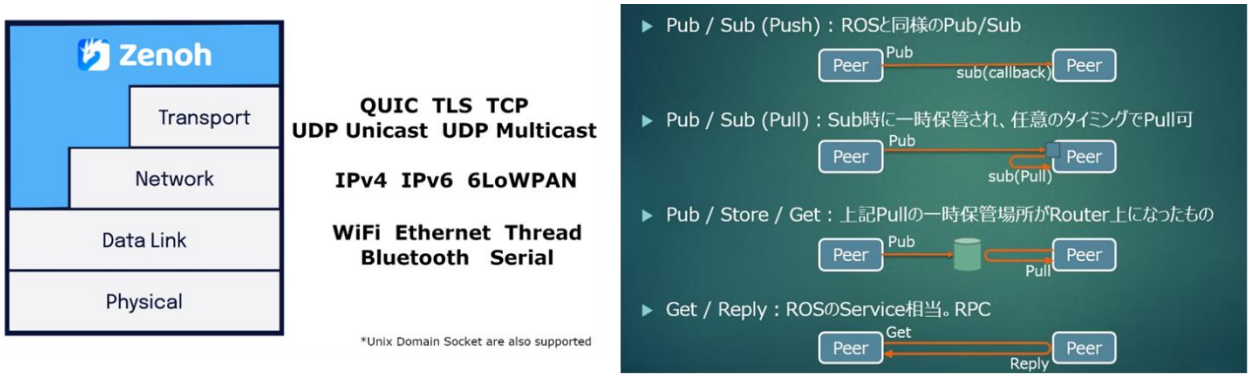

図の引用元： https://zenoh.io/blog/2022-08-12-zenoh-serial/

図の引用元： https://qiita.com/Shintaro_Hosoai/items/0bde489cde43a00d6f96

図　３．７．７－２　Zenoh の概要

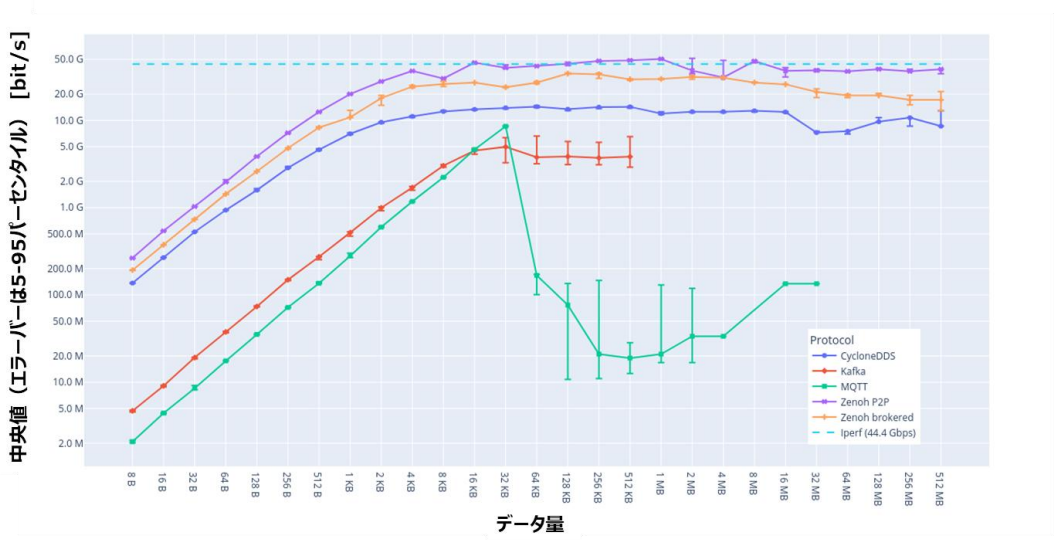

図X Throughput data in bit/s for the multiple-machine(※) scenario [1]

[1] Wen-Yew Liang et al.(2023), *A Performance Study on the Throughput and Latency of Zenoh, MQTT, Kafka, and DDS*, arXiv:2303.09419

(※)multiped-machineとあるが、2台のコンピュータ間での通信テスト結果

図　３．７．７－３　Zenoh と他の方式の比較

表　３．７．７－２　通信方式検討経緯の整理

	ACS - VTP	VTP or ソルバIF - HATS FMS	HATS FMS – ロボット	備考
先行試作	(N/A)	Get / Reply	Pub / Sub	(N/A)
案1	Pub / Sub	Pub / Sub	Pub / Sub	こちらを採用
案2	Get / Reply	Get / Reply	Pub / Sub	ACS/VTP改修規模大

３．７．７．３ 通信フォーマット

具体的な通信メッセージの内容をこのように定義した。詳細はインターフェース定義書を参照。
送信周期は双方ともに 0.1 秒とした。

VTP Plant→HATS（周期送信）

```
{
  "List": [
    {
      "MbId": 1001,
      "UpdateFlag": false,
      "PathListId": 2,
      "PMTNodeId": 401
      "PathInfoList": []
    },
    {
      "MbId": 1002,
      "UpdateFlag": true,
      "PathListId": 1,
      "PMTNodeId": 305
      "PathInfoList": [
        {
          "PathListId": 0,
          "NodeId": 305,
          "RunRuleId": 1,
          "MaxVelocity": 1.79999995
        },
        {
          "PathListId": 1,
          "NodeId": 400,
          "RunRuleId": 2,
          "MaxVelocity": 2.79999995
        }
      ]
    }
  ]
```

1001はPathInfoList更新なし

1002はPathInfoList更新あり

全Mb分、毎回送信する

Update flag = true if (path OR permit変化)

PathInfoList[]部分は、変化なければ空文字列

HATS→VTP Plant（周期送信）

```
{
  "List": [
    {
      "MbId": 1001,
      "UpdateFlag": "true",
      "PathListId": 2,
      "RealNodeId": 305,
      "WorkCompletionFlag": "true"
      "X" : 0.1,
      "Y" : 0.5,
      "Z" : 0
    },
    {
      "MbId": 1002,
      (以下略)
    }
  ]
}
```

Update flag = true if (PathListIdが前回送信から変化)

WorkCompletionFlag = true if (作業完了)

X, Y, Zはm単位

図 ３．７．７－４ VTP-HATS 間通信フォーマットサンプル

３．７．７．４ 開発環境の構成

開発ステップごとに、下表に示すような構成にて動作確認を行った。それぞれの構成の模式図を続いて示す。

表 ３．７．７－３開発環境一覧

	条件		構成	
No.	シミュレータ or実機	ロボット台数	Windows PC	Ubuntu 22.04 PC
1	gazebo シミュレータ	1台	1台	なし
2	gazebo シミュレータ	複数台	1台	1台
3	実機	複数台	1台	5台 （FMS1台, edge4台）

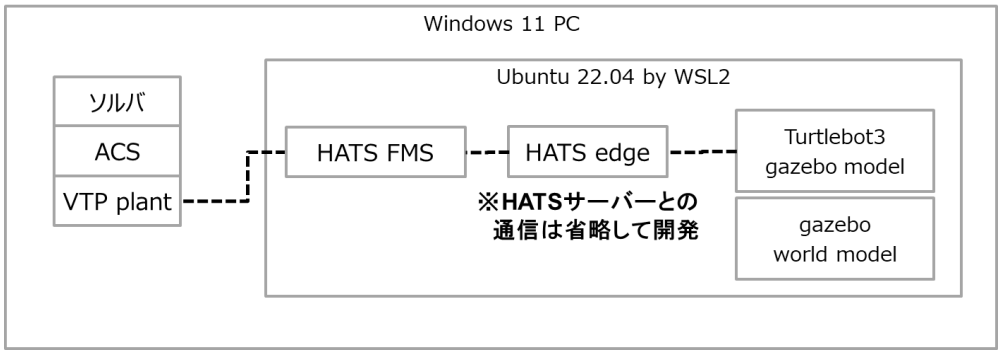

図 ３．７．７－５ gazebo シミュレータ、ロボット１台構成の開発環境

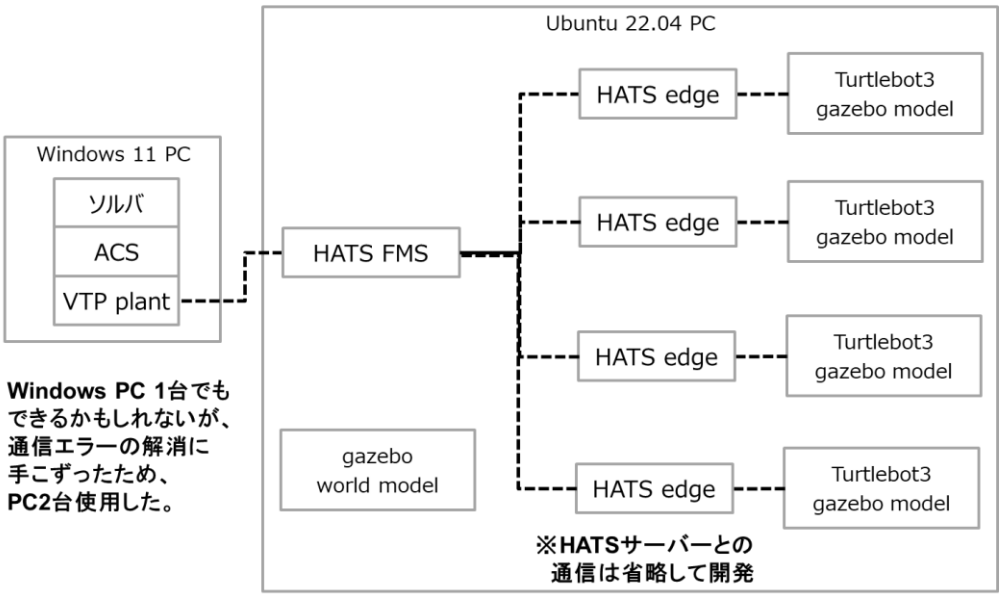

図 ３．７．７－６ gazebo シミュレータ、ロボット複数台構成の開発環境

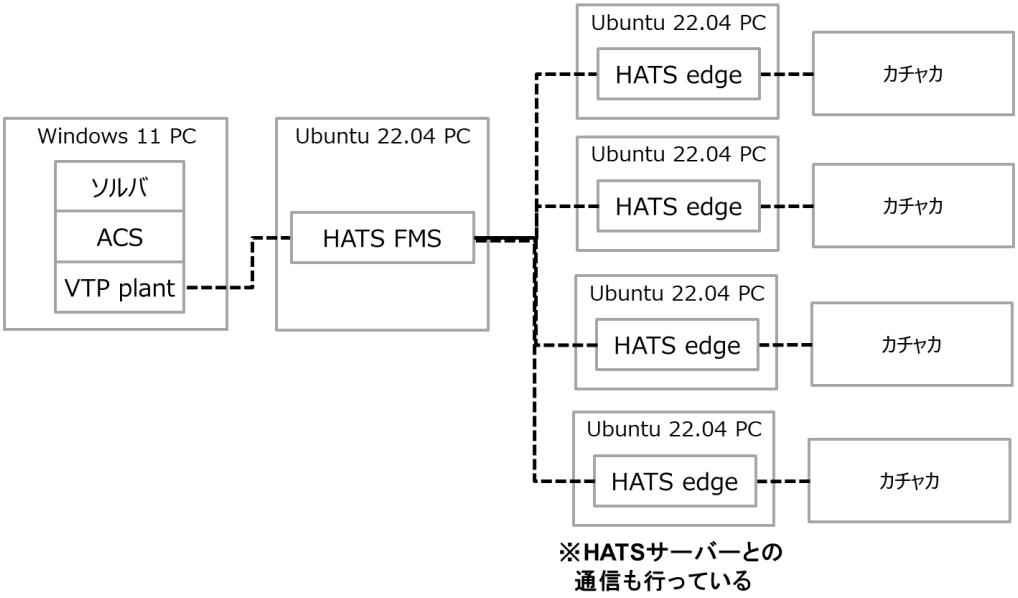

図　３．７．７－７　実機の開発環境

３．７．７．５ これまでの動作状況

動作確認結果を示す。

gazebo シミュレータにおけるロボット複数台動作の動画

実機におけるロボット複数台動作の動画

実機実験で遭遇した不具合事象と対策の整理

（１）　動作状況 1: gazebo シミュレータ、ロボット複数台

- **以下の観点でマップ作成**
  - **キビテク大崎オフィスに概ね収まる**
  - **一方通行の閉ループ×2を交差**
  - **ノード間70cm**
    - **カチャカ（実機テストで用いるロボット）全長40cm**
    - **実環境の自己位置精度30cm**
- **ノード到着判定基準**
  - **並進25cm**
  - **方位5deg**

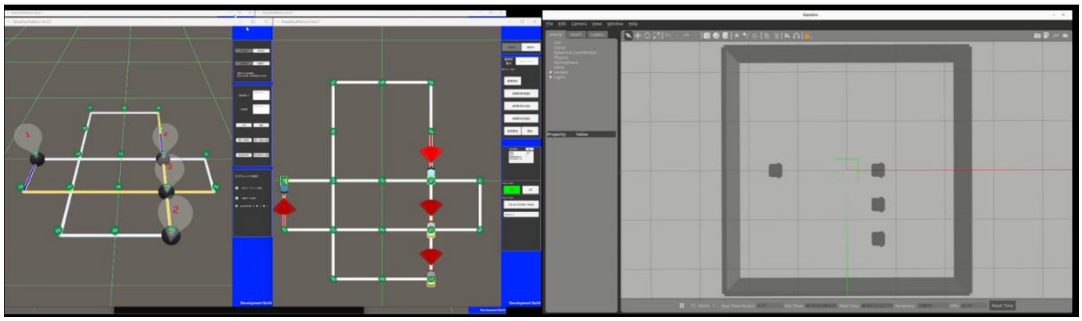

（２） 動作状況 2：実機 4 台

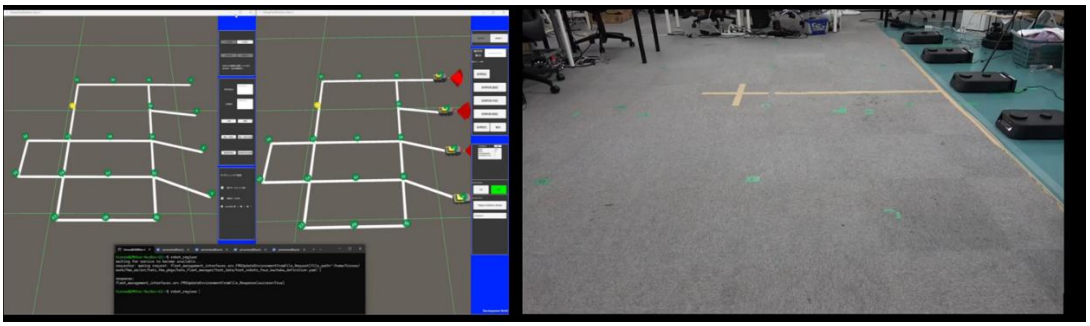

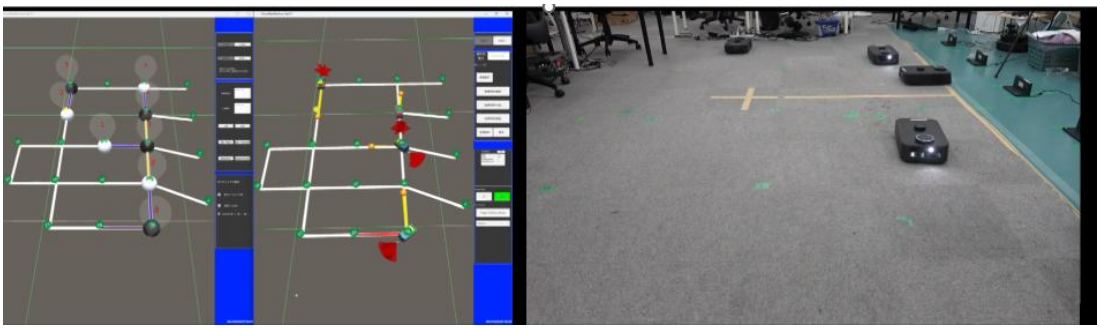

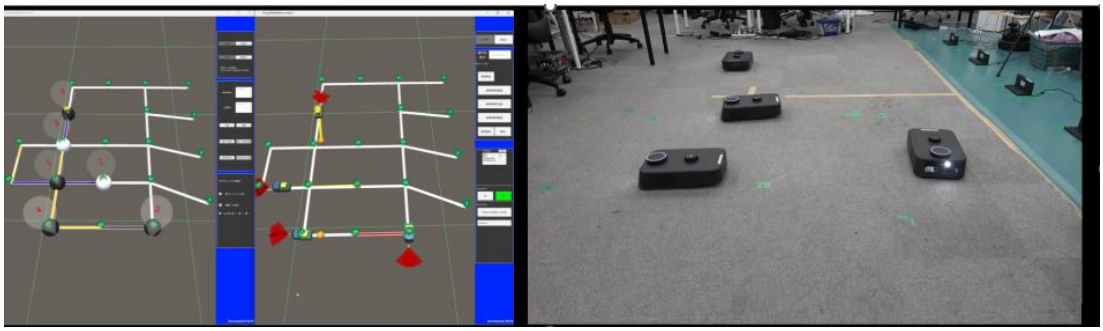

３．７．８ 実機テストの実施

３．７．８．１ 試験場

実機テストは、日本大学津田沼キャンパスの振動実験室を借用した。実験室は、工場での突発事象に適した環境である。

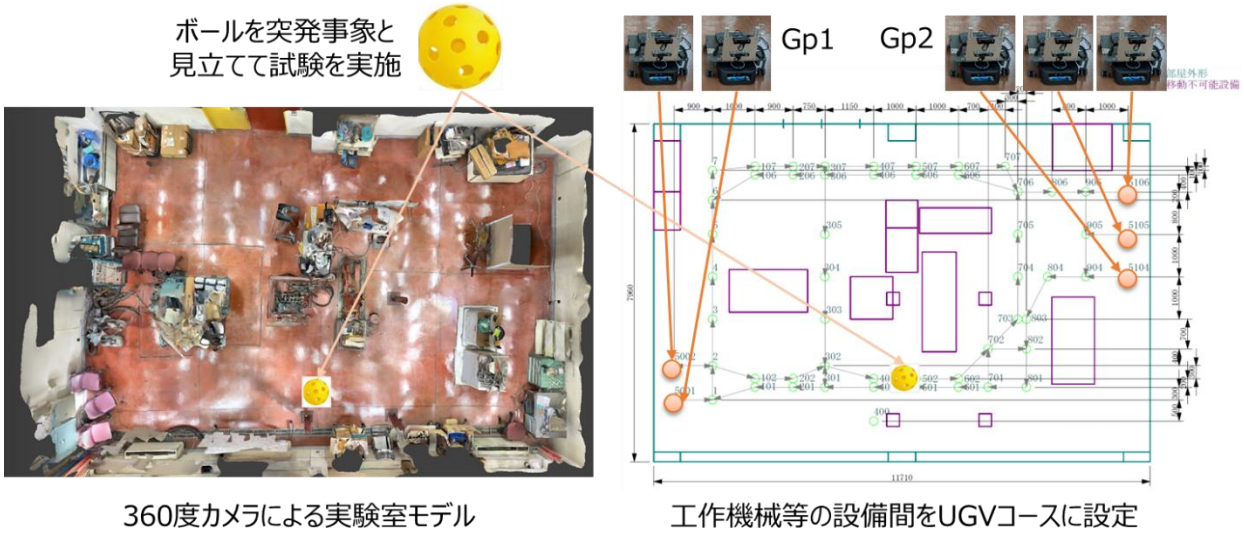

図　３．７．８－１　実機テスト試験場概要（日本大学生産工学部振動実験室）

３．７．８．２　試験概要

想定シナリオと結果を以下に示す。

表　３．７．８－１　実機テスト想定シナリオと結果概要

#	想定シナリオ名称	結果概要	備考
0	通常時（比較用）	動的リスクが存在しない場合には最短経路を生成した。	合格
1	定点カメラ物体検知・リスク迂回	定点カメラが物体検知しリスク判定→リスク回避する経路を生成・再生成した。	合格
2	移動体カメラ物体検知・リスク迂回	移動体が物体検知しリスク判定し、他の移動体がリスク回避する経路を生成・再生成した（図　３．７．１－２参照）。	合格（図示）
3	渋滞迂回	移動体2台が渋滞し、他の3台の移動体が渋滞回避して迂回する経路を生成した。	合格
4	T字合流制御	T字路で左右から移動体2台・3台が合流地点に向かい、ACSの指示に従い待合氏、1台ずつ通過した。	合格
5	長距離テスト	システムの安定性、可用性の簡易評価。18分程度走行し、最終的に5台中4台を撤去したが、最後の1台は全てのゴールをこなした	合格

本来想定される場面では、物体の具体例は侵入者、不審者であるが、今回は機能検証を目的としているため、実験の再現性を担保するために、安定して検知され、かつ実験場所内を移動する時に検知される他の物体とクラス分類が重複しない、下図の写真のようなボールを用いた。

図　３．７．８－２AI カメラ検知対象の侵入者の代替

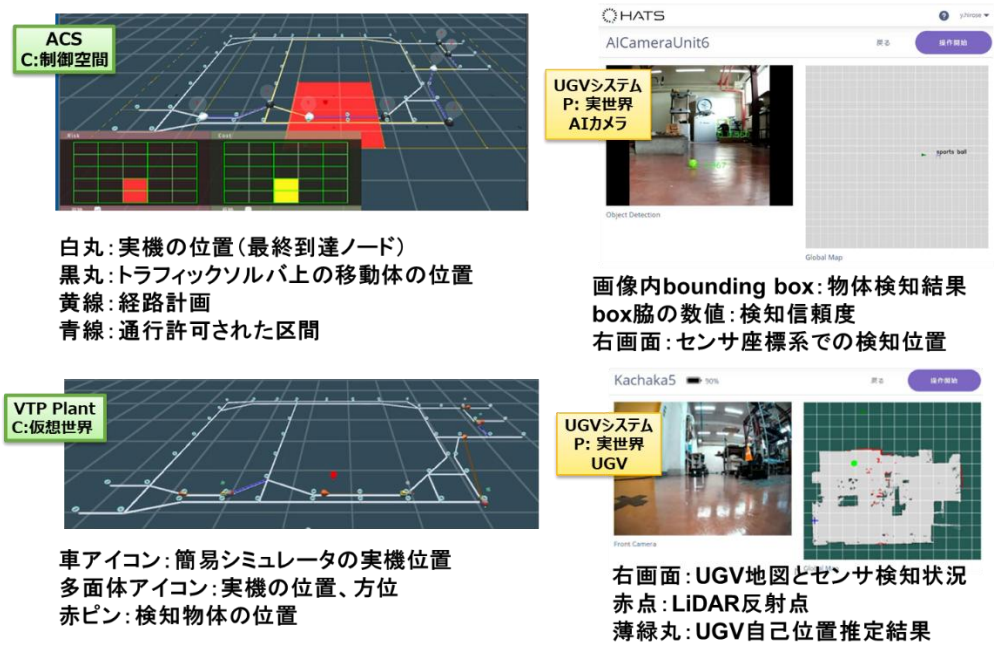

図　３．７．８－３画面の各要素の意味

（１）　シナリオ０：通常時（比較用）

場面：動的リスクが存在しない場合には最短経路を生成する

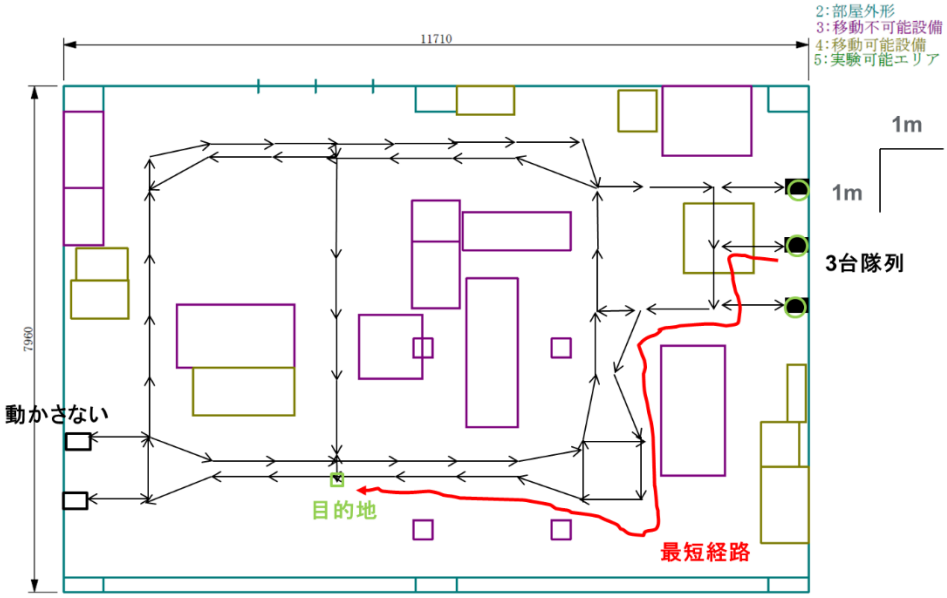

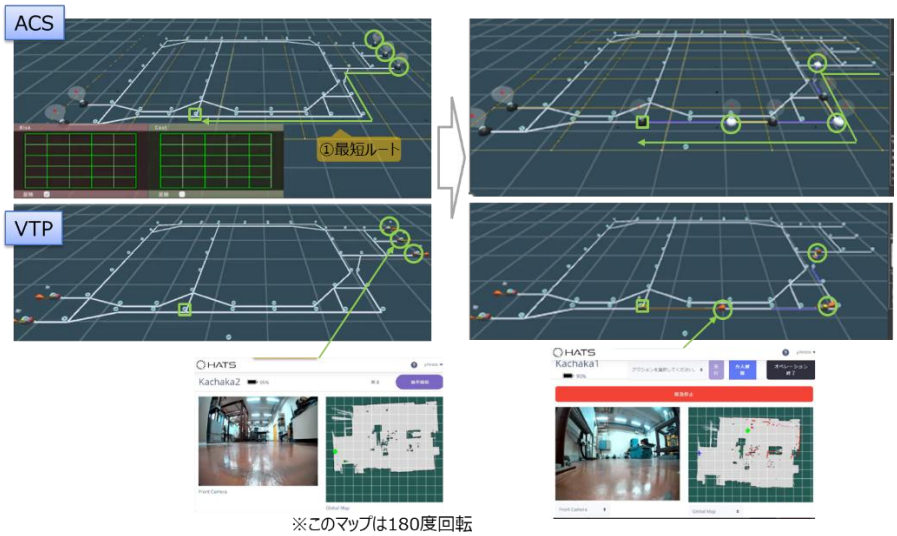

※このマップは180度回転

0:00	**移動開始**：UGVが経路生成・出発。
0:50	右側の画面をKachaka2 -> Kachaka1に切替。 柱の近くで自律制御が停止しかかっていたので、 マニュアル操作による介入で前に進ませた。
1:23	3台全ての移動体が終端に到達。

0:12	**移動開始**：UGVが出発。

0:21	1台目（赤）が最短経路である右方向へ進む。 以後、2台目、3台目（青、黄）も同様。

（２）　シナリオ１：定点カメラ物体検知・リスク迂回

場面：　定点カメラが物体検知しリスク判定する。その結果、リスク回避する経路を生成・再生成する。

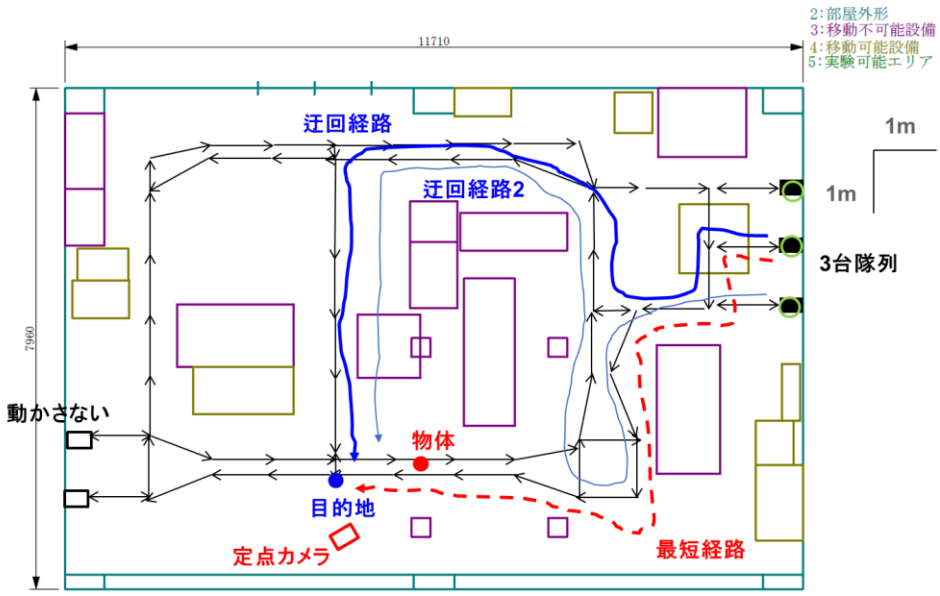

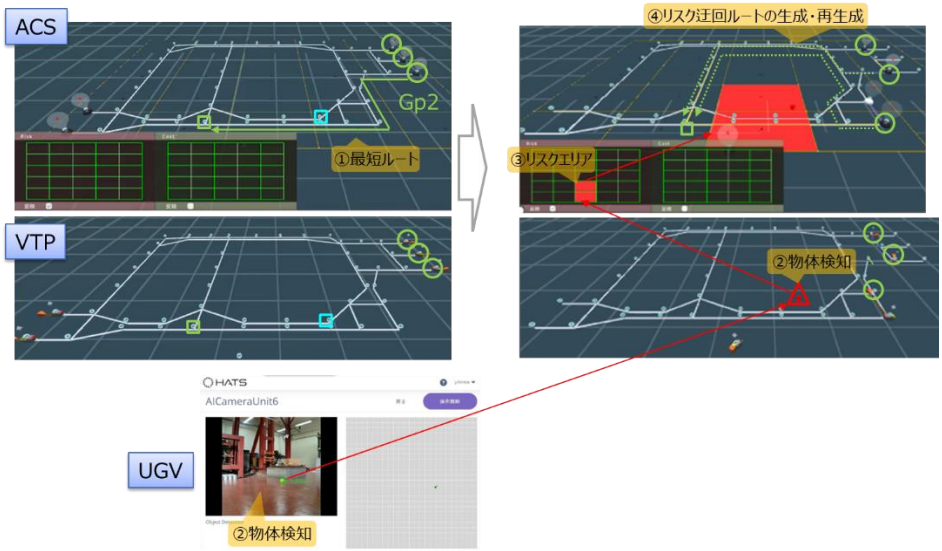

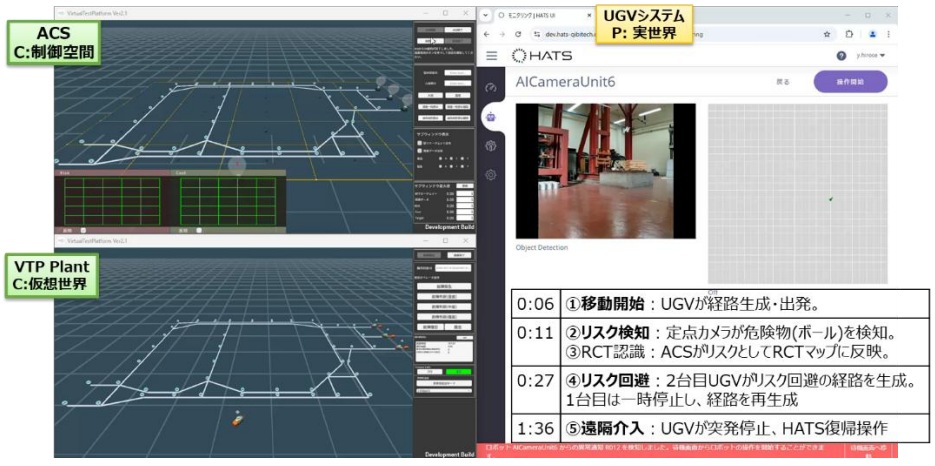

0:06	**①移動開始**：UGVが経路生成・出発。
0:11	**②リスク検知**：定点カメラが危険物(ボール)を検知。 **③RCT認識**：ACSがリスクとしてRCTマップに反映。
0:27	**④リスク回避**：2台目UGVがリスク回避の経路を生成。 1台目は一時停止し、経路を再生成
1:36	**⑤遠隔介入**：UGVが突発停止、HATS復帰操作

0:11	**②リスク検知**：危険物(ボール)が出現し、定点カメラが検知。

0:13	**①移動開始**：UGVが出発。

0:41	**④リスク回避**： Gp2の1台目UGV（赤）が経路再生成により、 元来た方向へ引き返し、リスク回避の経路（左方向）を進む。 ※Gp2の3台（赤青黄）にとって右方向が最短経路、左方向がリスク回避の迂回経路。

（３）　シナリオ２：移動体カメラ物体検知・リスク迂回

場面：Gp1 の 1 台が物体検知しリスク判定する。その結果、Gp2 の 3 台はリスク回避する経路を生成・再生成する。

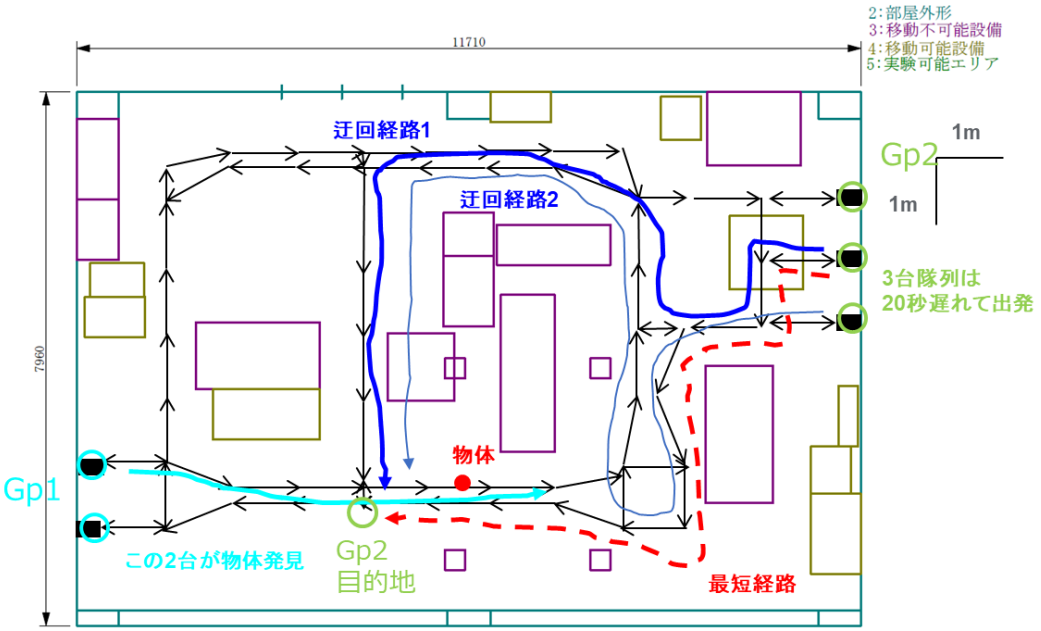

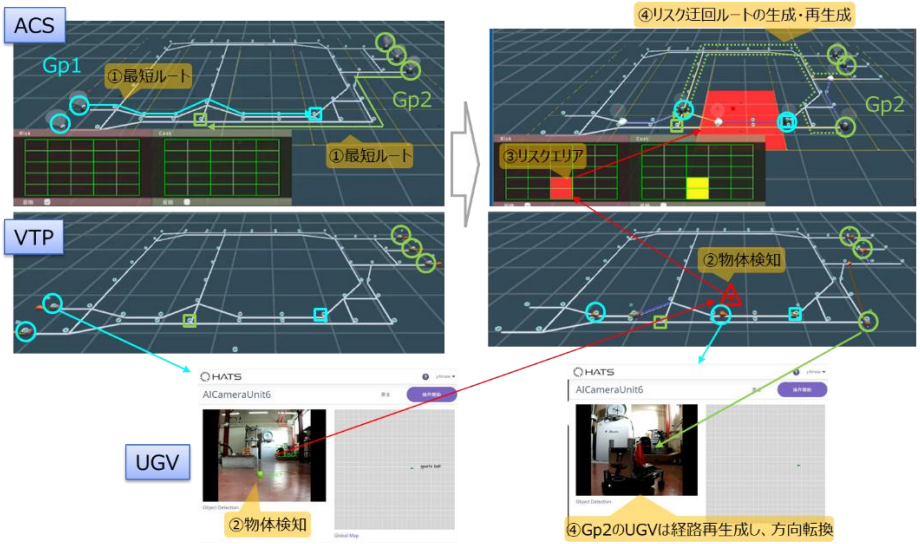

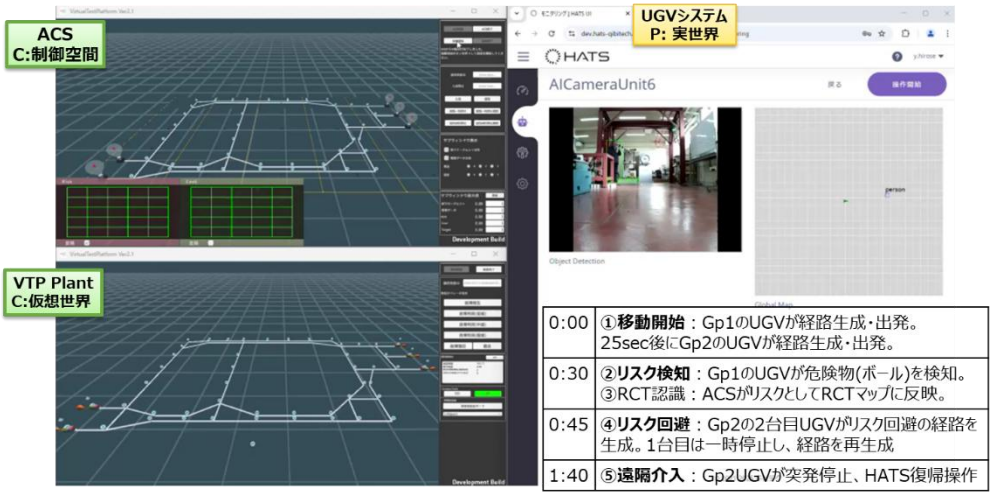

0:00	**①移動開始**：Gp1のUGVが経路生成・出発。 25sec後にGp2のUGVが経路生成・出発。
0:30	**②リスク検知**：Gp1のUGVが危険物(ボール)を検知。 ③RCT認識：ACSがリスクとしてRCTマップに反映。
0:45	**④リスク回避**：Gp2の2台目UGVがリスク回避の経路を生成。1台目は一時停止し、経路を再生成
1:40	**⑤遠隔介入**：Gp2UGVが突発停止、HATS復帰操作

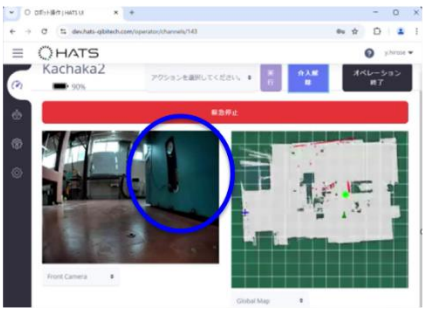

1:45	右側の静止物に近いため、自動制御では進めない

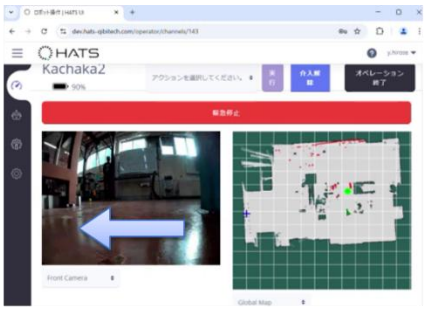

1:52	手動介入により左方向にその場回転

※画面下部の
上記ボタンで
マニュアル操縦

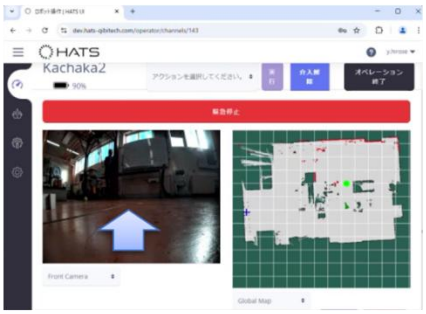

1:56	手動介入により前進

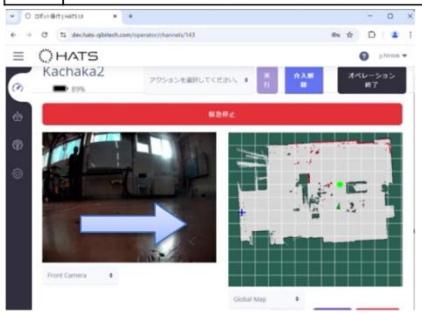

2:00	手動介入により右方向にその場回転 → 自動制御復帰

0:27	**①移動開始：**Gp2のUGV（赤青黄）が経路生成･出発。

0:54	**④リスク回避**： Gp2の2台目UGV（青）がリスク回避の経路（左方向）を進む。 1台目（赤）は経路再生成により元来た方向へ引き返す。 ※Gp2の3台（赤青黄）にとって右方向が最短経路、左方向がリスク回避の迂回経路。

1:00	**④リスク回避**： Gp2の1台目、2台目UGV（赤、青）がリスク回避の経路（左方向）を進む。

（４） シナリオ３：渋滞迂回

場面： Gp1 の 2 台が渋滞する。その結果、Gp2 の 3 台は渋滞回避して迂回する経路を生成する。

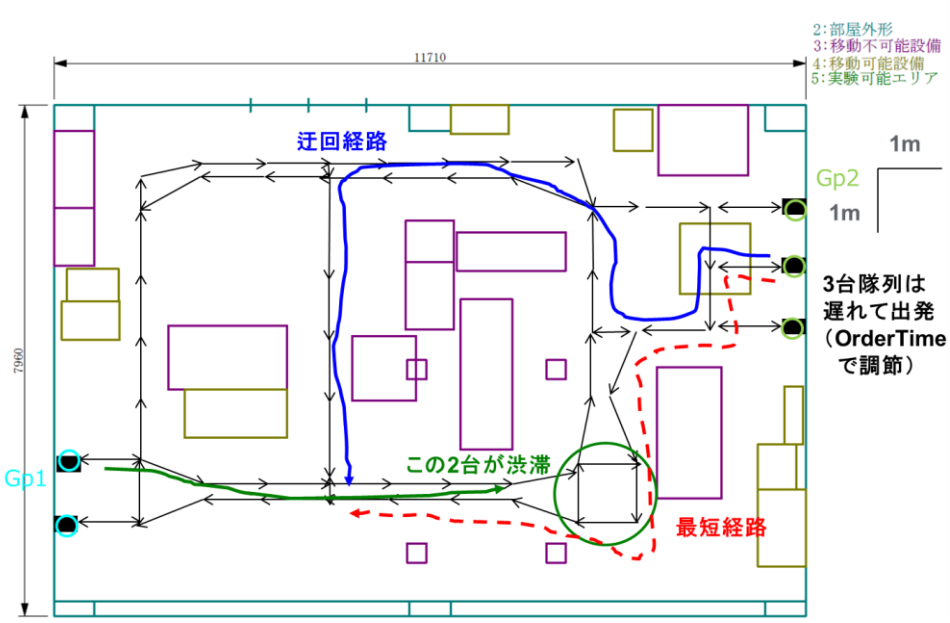

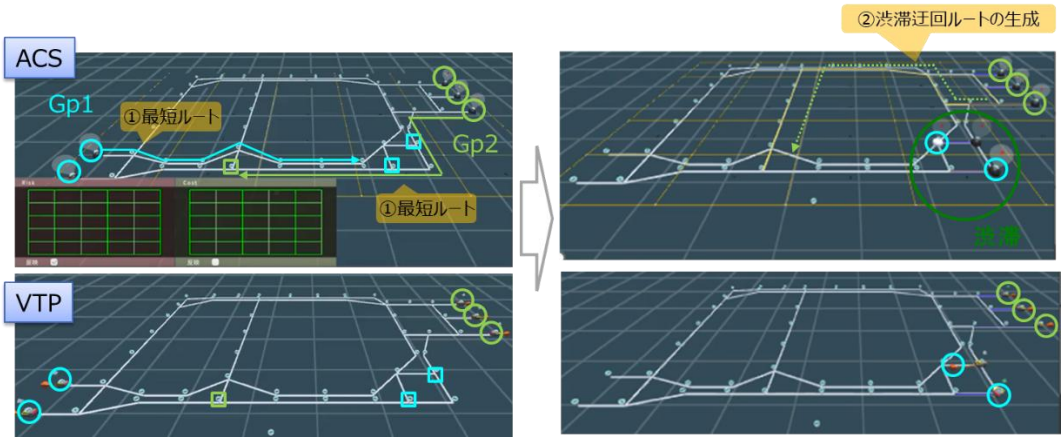

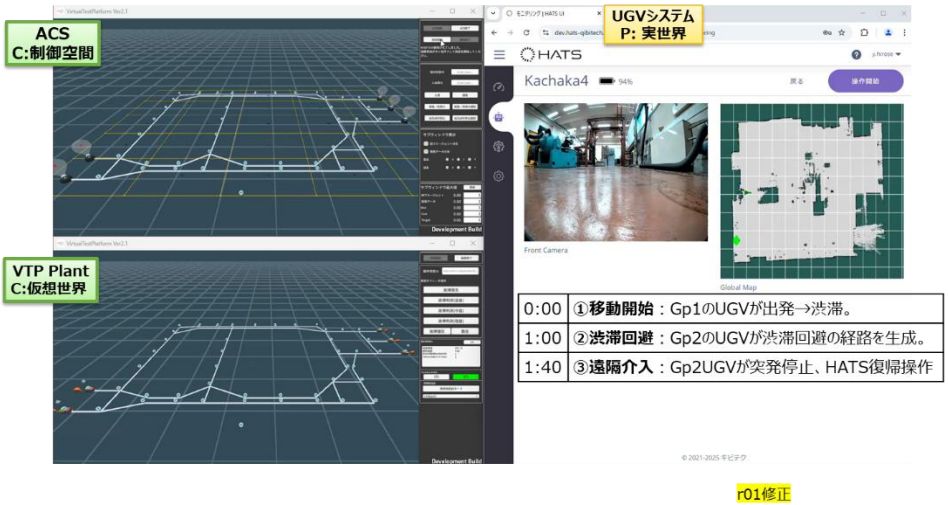

0:00	**①移動開始**：Gp1のUGVが出発→渋滞。
1:00	**②渋滞回避**：Gp2のUGVが渋滞回避の経路を生成。
1:40	**③遠隔介入**：Gp2UGVが突発停止、HATS復帰操作

r01修正

0:56	**①移動開始**：Gp1の2台目（橙）が画面に登場→渋滞。

1:21	**②渋滞回避**：Gp2の1台目（赤）が渋滞回避の経路（左向き）へ進む。（以後、2台目、3台目（青、黄）も同様）

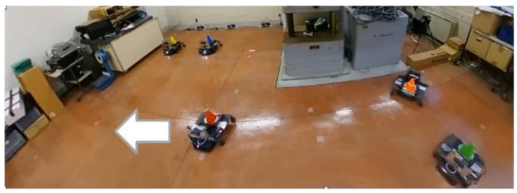

1:30	**②渋滞回避**：Gp2の1台目（赤）が渋滞回避の経路（左向き）へ進む。（以後、2台目、3台目（青、黄）も同様）

（５）　シナリオ４：T字合流制御

場面： Gp1の2台とGp2の3台が左右から同じ地点に向かい、ACSの指示で1台ずつ合流する

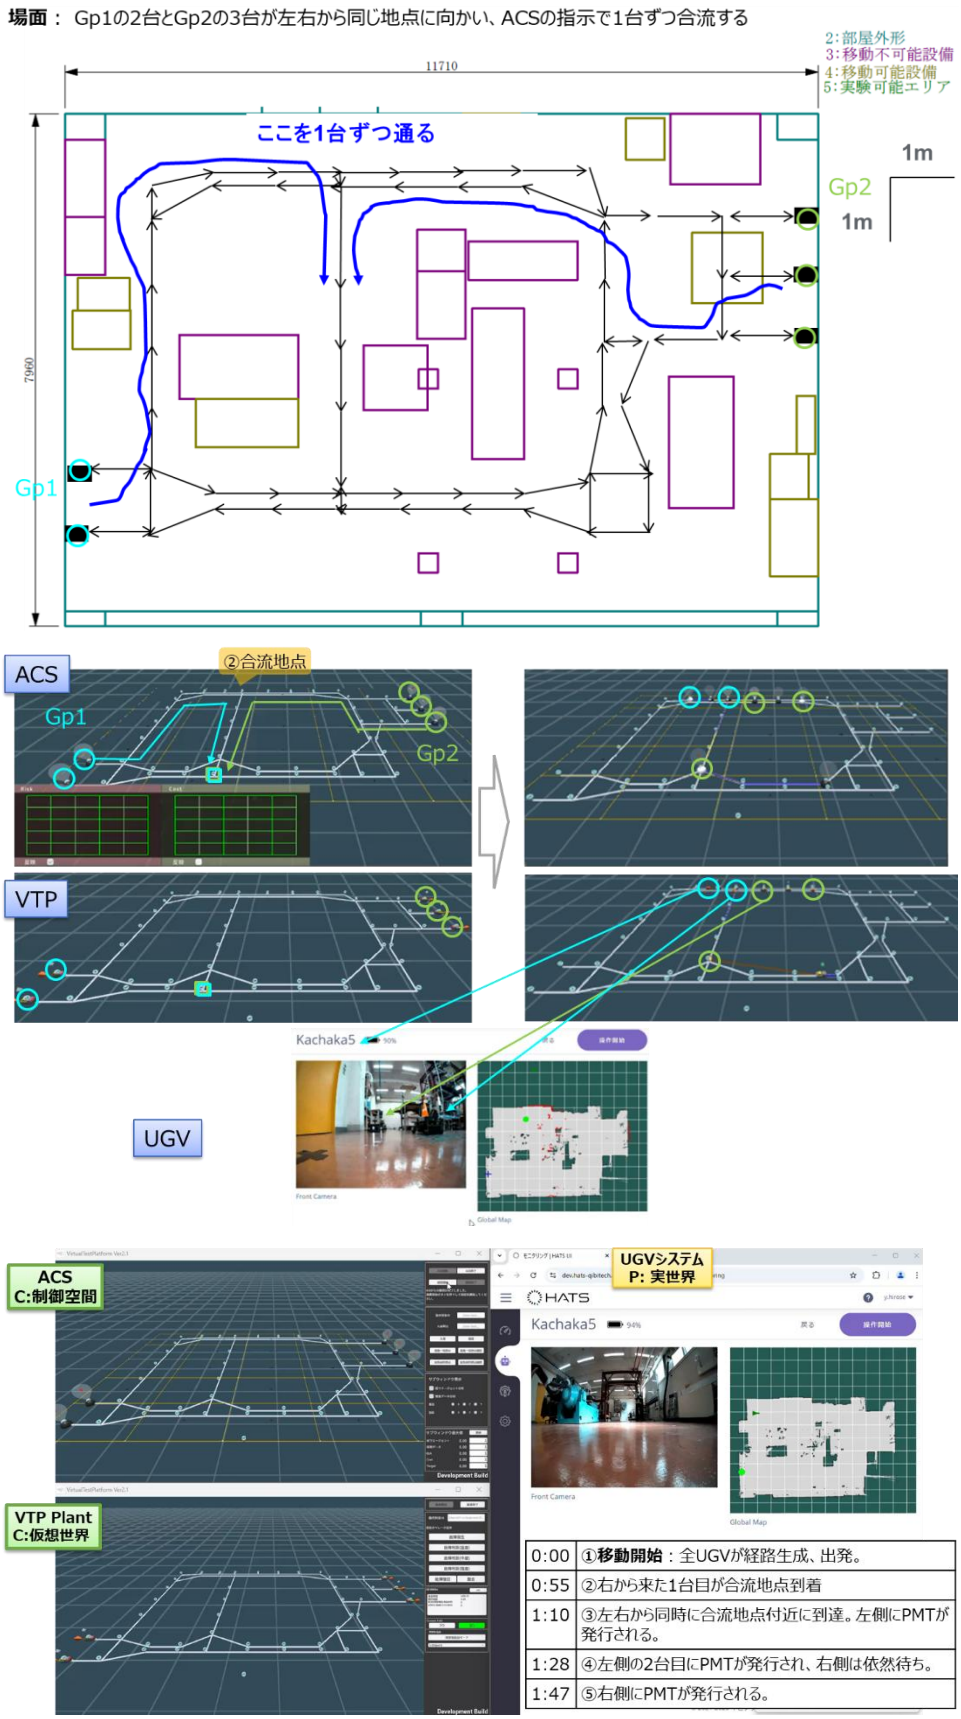

0:00	①**移動開始**：全UGVが経路生成、出発。
0:55	②右から来た1台目が合流地点到着
1:10	③左右から同時に合流地点付近に到達。左側にPMTが発行される。
1:28	④左側の2台目にPMTが発行され、右側は依然待ち。
1:47	⑤右側にPMTが発行される。

1:09	③左右から同時に合流地点付近に到達。左側（橙）にPMTが発行される。

1:27	④左側の2台目（緑）にPMTが発行され、右側（青）は依然待ち。

1:46	⑤右側（青）にPMTが発行される。

（６）　シナリオ５：長距離テスト

目的：システムの安定性、可用性の簡易評価

・全ノードをシャッフルして FromTo のゴールに設定

・スタックした場合、HATS での手動介入や MB 撤去して残りで継続

結果：18 分程度走行し、最終的に 5 台中 4 台を撤去したが、最後の 1 台は全てのゴールをこなした

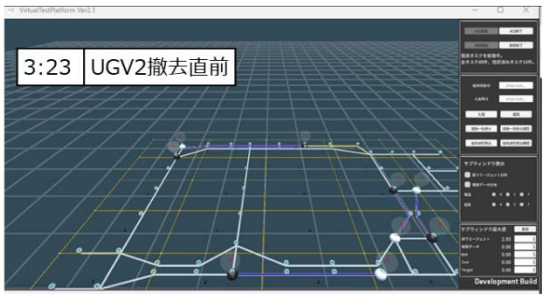

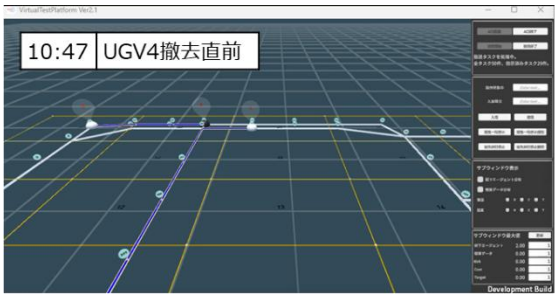

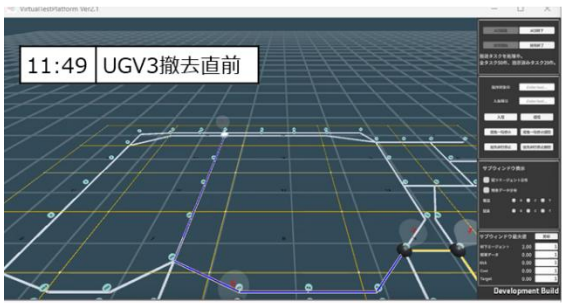

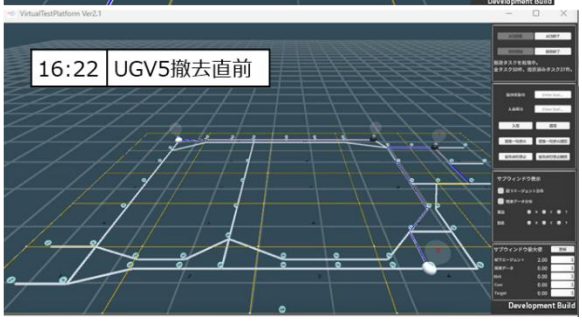

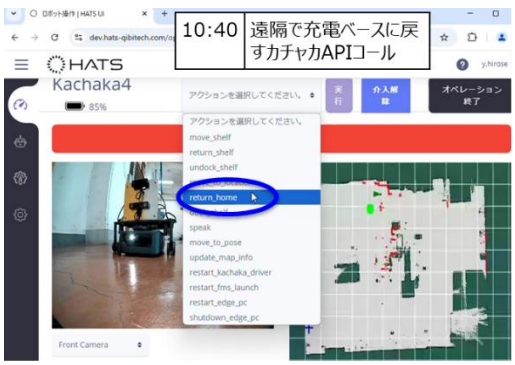

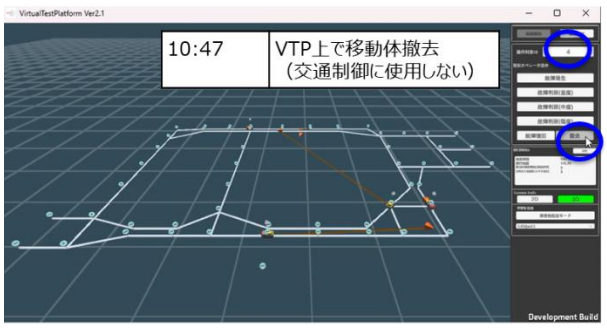

15:15
左側の静止物に近いため、
自動制御では進めない
HATS
Kachaka5
緊急停止
Front Camera

15:18
手動介入により右方向に
その場回転
HATS
Kachaka5
緊急停止
Front Camera
※画面下部の
上記ボタンで
マニュアル操縦

15:20
手動介入により前進
HATS
Kachaka5
緊急停止
Front Camera

15:23
手動介入により左方向にその場回転
→ 自動制御復帰
HATS
Kachaka5
緊急停止
Front Camera

４．　委託業務全体の成果
４．１　計画時に想定していなかった成果（副次的成果）や、目標を超える成果

４．１．１ 副次的成果
（１）　マルチエージェント技術体系の構築

本研究では、中間評価後に千葉大学 荒井幸代教授および日本大学 古市昌一教授の助言のもと、研究内容の再構成を行い、「**RCT-OODA 群制御 AI アーキテクチャ**」を中核とする**マルチエージェント技術体系**として再定義することに成功した（下図参照）。

この再構成により、当初の想定成果であった「RCT-OODA 群制御 AI アーキテクチャ」および「汎用マルチエージェント基盤 MAARC」に加え、以下の**副次的成果**が得られた：

- **絵図・知識・運動系 AI**：専門家の思考法を着想源とする新たな知能原理の提案
- **AI システム設計論（構造）**：AI・制御統合のための分割・統合・抽象化の設計論の明確化
- **社会実装アーキテクチャの着想**：実運用への展開を意識した AI アーキテクチャ設計視点の獲得

とくに、**マルチエージェント技術体系の全体像を概念整理・構造化できたこと**は、今後の研究や社会実装に向けた重要な基盤となる。これらは、研究の新規性・独創性・革新性を高める成果であり、本研究が AI アーキテクチャ設計の学術的枠組みに寄与するものであると位置づけられる。

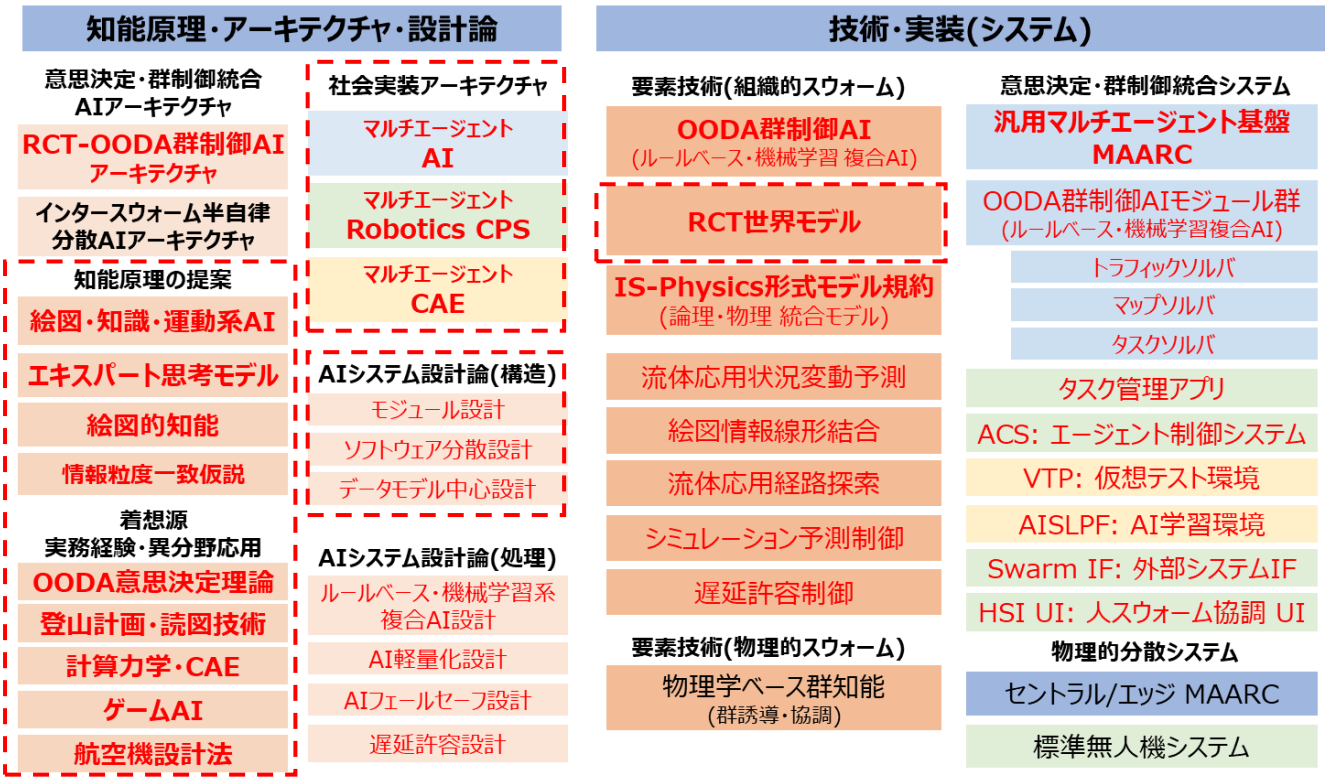

図　４．１．１－１　無人機マルチエージェント技術体系（赤字が本研究の成果）

（２）　インタースウォーム構想

インタースウォームとは、複数スウォームが協力して任務を遂行するためのマルチエージェントAI・ロボット連携の枠組みである（図　４．１．１－２参照）。インタースウォーム上で学習したマルチエージェントAIは、同じ組織の人のように共通の記憶基盤と立場に応じた思考回路を持ち無人機を操作する。不完全情報下の大規模な連携作業において、トップダウンとボトムア

ップの両アプローチに対応し、強靭で柔軟な意思決定と行動の実現を目指す。また、インタースウォームはマルチエージェントAI研究の促進を目指す。研究者がAI研究環境を構築する手間を省き研究を効率化し、研究グループ間のデータ相互運用性を向上させ、知見や成果の共有を容易にすることが期待される。

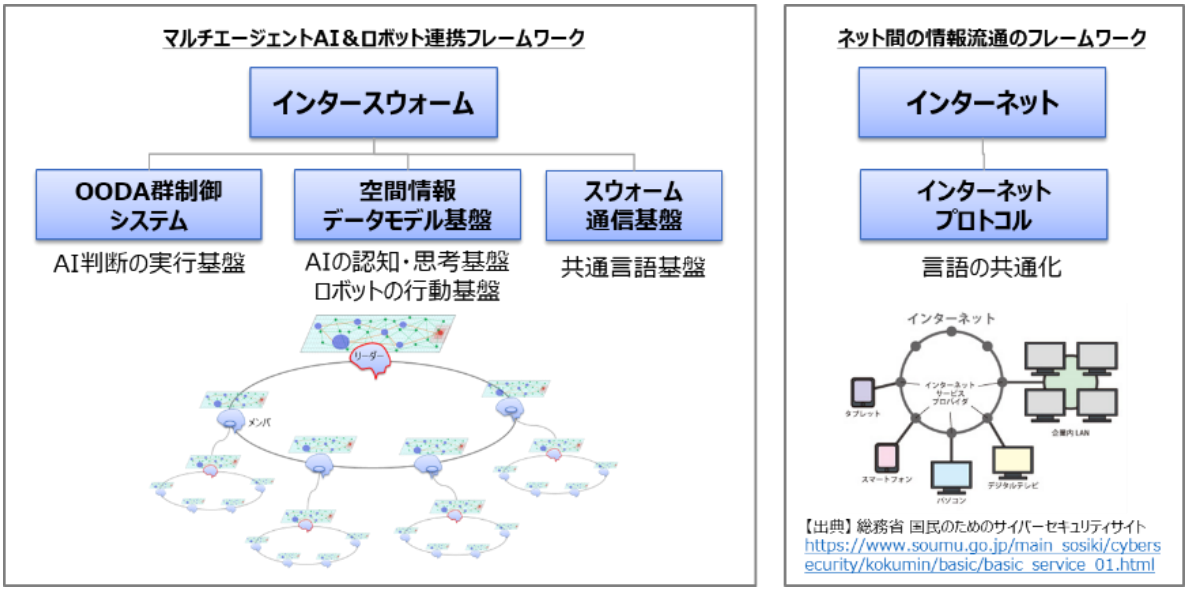

図　４．１．１-２　インタースウォームの概念図

インタースウォームは、複数エージェントが協力して任務を遂行するマルチエージェント AI・ロボット連携基盤・フレームワークである。（情報パケットを物流パケットに置き換えたフィジカル インターネットとは異なる。）

４．２　研究課題の発展性（間接的成果を含む）

４．２．１ 見通し

本研究で構築した**RCT-OODA群制御AIアーキテクチャ**および**汎用マルチエージェント基盤MAARC（Multi-Agent AI, Robotics CPS, and CAE Platform）は、意思決定と群制御を統合的に扱う新たなAIシステムアーキテクチャ**であり、以下の観点から学術分野および産業分野の発展に広く貢献する可能性がある。

（１）　学術分野への波及

- **AIアーキテクチャ設計論の深化**：OODAループを基軸とした認知モデル、CAEベースのモデリング技術、ゲームAIの階層的意思決定技術を融合した構成は、AI設計論に新たな視座を提供する。
- **マルチエージェント研究の体系化**：組織的・物理的スウォームを接続するための世界モデル設計や抽象化理論は、分散AI・群知能・HSI（Human-Swarm Interaction）研究の基盤として有用。
- **信頼性工学との接続**：AIフェイルセイフ設計、ロジック支援型AI、適用可能な判断粒度理論は、AI信頼性研究の枠組み拡張につながる。
- **学際的連携の促進**：知能科学、認知工学、ロボティクス、計算力学など異分野融合研究の枠組みとして活用でき、応用範囲は広い。

（２） 産業分野への波及

- **無人機運用・自律システム開発**：群制御を前提とした意思決定支援機構は、災害対応・物流・監視・警備・農業など、無人機を活用する各種分野での導入が見込まれる。
- **スマート交通・搬送・製造業**:群最適化やリアルタイム制御に対応したアーキテクチャは、AGVや搬送ロボットの自律化、工場自動化などの実装にも直結する。
- **AIの安全性・運用信頼性の確保**：フェイルセイフ型AIやロジックとAIの協調構造は、社会受容性を重視する分野（医療、モビリティ、社会インフラ等）におけるAI適用の拡大に資する。

（３） 将来的発展の見通し

- 本研究は、既存の特化型AIとは異なる**モジュール構造・進化性・汎用性を備えたAI基盤**の方向性を示すものであり、今後の社会実装・国際連携研究・技術標準化への発展が期待される。
- 特に、**システム全体の抽象化構造と判断根拠の可視化を重視するAI設計哲学**は、AIの説明性・信頼性・運用性を同時に担保する技術的基盤として、次世代AIシステム設計の新たな潮流を形成するものと考えられる。

４．２．２ 今後の発展・波及における主なボトルネック

（１） 異分野統合の複雑性

- 本研究は、**AI・ロボティクス・CAE・認知科学・システム工学**など複数分野にまたがるため、実装において専門知識の統合や人的リソースの調整が必要。
- 特に、CAEや物理モデリング技術をAI設計に応用するには、従来のAI技術者にはないモデリングスキルが要求される。

（２） AI の信頼性・安全性の評価基準の未整備

- **フェイルセイフ型AI**や**複合AI設計（ルール＋ML）**のような新構造は、既存のAI性能評価・安全性認証の枠組みに収まらない場合がある。
- 特に、「ロジックとAIの切替」「判断根拠の可視化」などは、運用現場での**説明責任**や**社会受容性**の観点から評価指標の標準化が不可欠。

（３） 完全分散型実装のスケーラビリティ

- MAARCのような**物理分散・ソフトウェア分散**を前提とするAIプラットフォームは、**通信遅延**や**非同期性**の影響を大きく受ける。
- シミュレーションと異なり、実環境では**通信障害、応答遅延、ノイズ**などが大規模分散AIにとってボトルネックとなる。

（４） 実機試験の制約とコスト

- 群制御AIの評価には実環境・実機試験が必要だが、無人機や自律システムを多数運用するには安全確保、コスト、設備、制度的ハードル（航空法など）が存在。
- シミュレーション中心の開発では得られない現象もあり、試験環境構築への支援体制が不可欠。

（５） 人との協調（HSI）におけるインタフェース整備

- AIが自律化する一方で、**人とAIの協調・監視・介入**を保証する直感的で低負荷なインタフェース（HSI）が求められる。
- この分野では「ユーザインターフェース（UI）」「認知負荷評価」「信頼性可視化」などの設計指針が未成熟である。

（６） **標準化と社会実装までのギャップ**

- MAARCやRCT-OODAアーキテクチャのような**新しいAI設計論**は、標準化団体や産業界との連携が進んでおらず、**社会実装に向けた制度整備や実装テンプレート**が未整備。

４．２．３ 個別の取組み

本研究で得られた成果は、マルチエージェントAIおよび群制御AIに関する新たなアーキテクチャと応用基盤を提示するものであり、次に示す**学術・産業分野の発展に幅広く寄与する見通し**がある。

学術分野においては、日本大学との連携により、シリアスゲーム環境を活用したマルチエージェントAIの意思決定・協調制御に関する基礎研究が進められている。また、第一工科大学および明治大学では、汎用マルチエージェント基盤「MAARC」を活用し、マルチエージェントシミュレーションAIや物理スウォーム研究に取り組んでいる。加えて、千葉大学とは、計算力学・CAE技術とAI設計の融合を目的とした研究交流を進めており、工学とAIを統合する新たな学際領域の形成が期待される。

さらに、**研究代表者自身が日本大学大学院に博士課程学生として進学し、RCT-OODA群制御AIアーキテクチャやRCT世界モデルを対象とした学術的研究を本格的に開始**しており、本研究の成果を学術的に深化させる基盤が整備されつつある。この取り組みにより、理論的枠組みの体系化と国際的な研究発信が加速されることが期待される。

産業分野においては、物流分野のロボット研究開発Sierに対してMAARC技術のライセンス提供を予定しており、多機ロボットによる倉庫協調制御や最適化への応用が見込まれる。また、AI受託企業では、MAARCを含むマルチエージェントAI技術の再利用・再販体制を整備し、高度な意思決定支援AIの実装やシステム開発の効率化を進める見通しである。

さらに、防衛装備庁においては、MAARCを活用したシミュレーション研究を受託しており、実環境を模擬した高度AIの検証基盤としての貢献が期待される。また、UAV群制御プロジェクトの橋渡し研究では、MAARCを活用した実証研究に参画しており、防衛技術領域への実装フェーズに向けた重要な一歩となっている。

加えて、**研究成果の今後の発展に向けた取り組み**として、現在進行中の防衛装備庁のプロジェクトへの技術支援を通じて、群制御・意思決定AIの適用領域を拡大するとともに、R7年度の安全保障技術研究推進制度への応募を行った。R6年度までに確立した「RCT-OODA群制御AIアーキテクチャ」「MAARC」「RCT世界モデル」などの成果を土台とし、次フェーズでは完全分散型マルチエージェント強化学習や直感的HSI（Human-Swarm Interaction）など、応用展開を志向した研究へと進化させる計画である。

これらの取組みを通じて、本研究成果は学術界における理論的貢献と、産業界における実装的展開の双方に資する、汎用性と拡張性を備えた技術体系として、継続的に発展していくことが期待される。

４．３ 研究成果の発表・発信に関する活動

特になし。

５． プロジェクトの総合的推進

５．１ 研究実施体制とマネジメント

本研究では、限られた期間と資源の中で効率的かつ効果的に研究を進めるため、責任体制の明確化、人的資源の最適配置、役割分担、研究環境の整備、そして継続的なマネジメントの工夫により、柔軟で実行力のある研究実施体制を確立した。

研究代表者が全体統括およびAIアーキテクチャ設計を直接主導し、専門性を有する外部協力者（大学教員や顧問）との連携により、必要な知見を補完する体制を整備した。特に中間評価以降は、千葉大学 荒井幸代教授および日本大学 古市昌一教授の指導のもと、研究内容の抜本的な再構成を行い、学術的視点からの支援を受けながら技術的方向性の再定義と体系化を推進した。

研究機関間では、役割分担を明確に設定した。日本大学は実機試験フィールドの提供とマルチエージェント・シリアスゲーム研究への展開を担い、第一工科大学および明治大学は汎用マルチエージェント基盤MAARCの教育・研究応用を進めた。また、千葉大学はCAE技術とAI設計の融合に関する知見提供と研究交流を担った。

研究開発環境としては、MAARC上に仮想試験環境（VTP）および統合制御システム（ACS）を構築し、仮想環境と実機環境の応答ギャップを把握できるリアルタイムデジタルツイン環境を実現した。これにより、制御・シミュレーション・実機を一貫して評価できる構成を整えた。

また、週次の研究ミーティングを設け、アジャイル的な進行管理を実施し、課題の早期発見・即時対応によって、柔軟かつ実践的に研究を推進した。進捗や課題は継続的に共有され、メンバー間の役割調整や方針転換も迅速に行う体制を構築した。

さらに、研究代表者自身が日本大学大学院の博士課程に進学し、学術研究と本プロジェクトを横断的に統括することで、理論と実装を一貫して結び付ける高度な研究マネジメントを実現した。

これらの取り組みにより、研究はアーキテクチャ設計・実証・運用環境整備・学術展開の各側面においてバランスよく進展し、限られたリソースの中でも成果を最大化することができた。

５．２ 経費の効率的執行

本研究では、**実機テストにおける経済性と学術的波及効果の両立**を目指し、**日本大学生産工学部の振動実験室等の学内施設を借用**する形で試験環境を整備した。これにより、専用施設を新設することなく、実機検証に必要な空間的・技術的要件を満たすとともに、**大学との連携による学術展開の基盤強化**を実現することができた。

中間報告の段階で研究の中止が決定されたものの、これを単なる縮小に留めず、**成果の学術的および産業的活用に向けて、汎用マルチエージェント基盤MAARCの完成度を高めて、研究利用できるように整備した。**

このように、研究環境と経費面の工夫、さらに成果展開に向けた柔軟なマネジメント対応により、**研究資源の有効活用と将来展望の確保を両立**させることができた。

６．　まとめ、今後の予定

６.１　まとめ

本研究は、未知環境下においても高信頼かつ柔軟な自律運用を実現する、次世代型マルチエージェント制御システムの構築を目的とするものである。対象とする実用シナリオは、工場倉庫におけるAGV搬送管制および、重要拠点におけるUxV（無人航空機・無人地上車両）による遠隔監視であり、省人化や自律化が求められる実社会の課題に対応するとともに、多様な応用展開に向けた汎用性の向上を志向している。

本研究では、防衛やビジネス分野でも広く採用されつつある、動的意思決定の枠組みである「OODAループ意思決定理論」に基づき、「RCT-OODA群制御AIアーキテクチャ」を設計・構築した。このアーキテクチャは、計算力学（CAE）による空間構造表現と、ゲームAIに由来する階層的意思決定モデルを統合し、「RCT世界モデル」を中核に実装されたものである。中央制御とエッジ制御の双方に対応可能な柔軟かつ再利用性の高い構造を持ち、物理実装および仮想検証の両面で展開可能な設計となっている。

本アーキテクチャを中核とした汎用マルチエージェント基盤「MAARC」を構築し、仮想環境および実機環境の双方において、その有効性を確認した。とりわけ、工場搬送シナリオにおいては、誤侵入や故障といった突発事象に対し、OODAループの自律的判断により危険回避を実現することに成功した。また、スマート交通システムへの応用評価では、従来比で最大14.1%の搬送時間短縮を達成し、交通全体最適化に対する有用性を示した。

AIの信頼性を確保するため、ロジックAIと機械学習AIを組み合わせた「AI複合設計」を適用し、フェイルセイフ設計としての冗長化構造を構築した。加えて、MAARCに実装された仮想テスト環境（VTP）における異常検知機構により、未知環境における安全性と任務継続性の両立を実現している。さらに、CAE技術を応用した「RCT世界モデル」の導入により、AI判断根拠の可視化と学習入力の構造化・抽象化を実現し、学習効率と説明可能性の向上を図った。

本研究は、開始から1年未満で実施された中間評価において、「国際競争力および新規性の提示が不十分」との理由により継続中止の判断を受けた。しかしその後、千葉大学および日本大学の有識者の指導を受け、研究内容の抜本的な再定義を行い、技術体系を再構成した。その結果、研究成果は新規性・独創性・革新性を備えた体系として結実し、研究の再評価と発展的展開が可能な基盤を確立するに至った。

中でも特筆すべき成果は、新たに提案した知能原理「絵図・知識・運動系AI」である。本原理は、専門家の思考様式を参照し、従来の知覚・運動系AIと自然言語・知識系AIを統合する第三の知能形式として設計されたものであり、人間の構造的理解と判断様式を模倣するAI設計の新しい方向性を提示している。この知能原理に基づき、意思決定主体としての「組織的スウォーム」と物理行動主体としての「物理的スウォーム」の二層構造を接続するためのRCT-OODA群制御AIアーキテクチャを構築し、その実装基盤としてのMAARCにより、その適用可能性と拡張性を検証した。

以上により、本研究は、構造的知能原理・意思決定アーキテクチャ・AI信頼性設計・仮想／実機環境対応という複数の要素を有機的に統合し、次世代マルチエージェントAI制御技術の理論的・実装的基盤を確立したものである。

６.２　今後の予定

本研究により構築された「RCT-OODA群制御AIアーキテクチャ」および「MAARC（汎用マルチエージェント基盤）」は、未知環境における高信頼かつ柔軟なマルチエージェント自律制御の実現に向けた有効な知能基盤であることが示された。今後は、この成果を発展させる形で、さらなる高度化・汎用化・社会実装を目指し、安保研究R7へ応募申請を行った。

令和7年度以降に実施する研究では、本研究にて構築したMAARCを基盤としつつ、これを実機環境において物理的に分散実装することを主軸に据える。具体的には、UAVやUGV、センサノードなどから構成される実空間上の分散エージェント群に対して、AIによるOODAループを自律的に動作

させるための分散制御アーキテクチャを開発・実証する予定である。これにより、災害現場や警備監視領域など、情報不完備で通信遅延のある現場においても整合的な群制御を維持可能とする技術の確立を目指す。

あわせて、AIの意思決定精度と透明性のさらなる向上を目指し、マルコフゲームモデルを活用した中長期的な戦略判断の強化と、完全分散型マルチエージェント深層強化学習（MADRL）に基づく「チームプレーAI」の設計・開発に取り組む。この「チームプレーAI」は、情報共有が制限された環境においても、自律的に役割分担や協調行動が可能となる設計を志向しており、スケーラブルかつロバストな群知能の実現に資する。

さらに、直感的・低負荷な人-スウォーム協調インタフェース（HSI）の開発を並行して進める。ここでは、現場隊員が複雑なシステムを意識せずとも運用可能となるよう、絵図的知能を応用した命令体系の設計、AR/VRによる状況認識支援表示、ならびに自然言語・ジェスチャ入力などを活用した簡易命令インターフェースの試作を行う。これにより、人とAIスウォームが高信頼かつ直感的に連携できる運用基盤の構築を目指す。

これら一連の取組は、安保研究R7において、以下の三つの中核課題、①汎用マルチエージェント基盤 MAARCの物理分散化、②OODA群制御AIの高度化とチームプレーAIの確立、③直感的・低負荷なHSI（人-スウォーム協調）技術の確立、として構成した。これらの課題を通じて、AIの進化性・拡張性・説明可能性を高めつつ、現場実装を見据えたリアルタイム性・操作性・安全性のバランスを追求するものである。

以上を踏まえ、令和7年度には、実環境におけるOODA群制御AIの完全分散自律化と人-AI協調の両立を目指した研究開発を本格的に推進し、次世代のマルチエージェントAI技術の社会実装を加速させる方針である。

７．　研究発表、知的財産権等の状況

（１）　研究発表等の状況

種別	件数
学術論文	該当なし
学会発表	該当なし
展示・講演	2件
雑誌・図書	該当なし
プレス	該当なし
その他	該当なし

（２）　知的財産権等の状況

発明の名称	発明者	出願登録区分	出願番号（出願日）	出願区分	出願国	登録番号（登録日）
移動体の群制御システム及び群制御方法並びに移動体	高岡秀年	出願	特願 2025-048460 （2025/03/24）	国内		

（３）　その他特記事項

ワークショップや運営委員会等の開催状況を以下に示す。プロジェクトの立ち上げフェーズのため、全体の進捗を確認する定例会、研究員間の意思疎通を図るチームミーティングを定期的かつ適宜実施した。

年月日	開催名称	実施場所	備考
2023/11/8	全体ミーティング （兼 有識者レビュー）	クラスターダイナミクス株式会社	キックオフミーティング 研究代表者による 研究実施計画の紹介
2024/1/11	全体ミーティング	クラスターダイナミクス株式会社	各チームリーダーによる 実施計画説明会
毎週月曜日	定例進捗ミーティング	クラスターダイナミクス株式会社またはウェブ会議	進捗状況の確認、問題の共有と対策ミーティングの設定
毎日(初期) 隔日(月水金)	ACSソルバチームミーティング	クラスターダイナミクス株式会社またはウェブ会議	研究者・補助者の技術的な問題共有、解決策の協議、及び方針検討等を行う。
随時（月１）	ACSソルバ・AIチーム合同ミーティング	クラスターダイナミクス株式会社またはウェブ会議	チーム間の技術的な問題共有、解決策の協議、及び方針検討等を行う。