人と AI 群が協働するチーム対戦の取り組み

人間 30 人 vs 1 人のしっぽ鬼

Collaborating with an AI Swarm in an Adversarial Game

30 People vs One Person in Tail Tag

松波 夏樹
Natsuki Matsunami

三菱重工業株式会社
Mitsubishi Heavy Industries, Ltd.
natsuki.matsunami.aq@ds.mhi.com

唐鎌 聡太郎
Sotaro Karakama

(同 上)
sotaro.karakama.ks@ds.mhi.com

keywords: multi-agent, behavior tree, contract net protocol

Summary

Towards close collaboration between a human and a large number of AI systems, we propose to design an AI agent with two technical elements. The first is the use of a modeling approach that enables us to know what AI agents are trying to do. The second is the use of a multi-agent consensus building algorithm. A good combination of these two, a human and a group of AI agents were put together as one team. In this paper, we explain a configuration using a Behavior Tree and a Contract Net Protocol as a concrete example. In addition, we propose a method of applying reinforcement learning in which the intentions of the AI agents can be easily grasped by a human. The effectiveness and feasibility of this approach were evaluated with teams in a simulated Tail Tag game. Matches were held with up to 29 AI agents and 1 person on one team and 30 people on the other team. The results indicate that our approach works almost evenly with human-human collaboration by sharing roles between a human and AI swarm.

1. はじめに

農業や製造業などの社会活動をはじめ、災害対応等の非常的な社会基盤維持においても AI に期待される役割が増大している。特に労働力の減少が見込まれる日本では、少数の人間によって多数の事象に対処するため、人と多数のロボット群等の AI エージェント（以下 AI 群と呼ぶ）がチームワークを発揮し目的に指向して協働することが欠かせない。しかしながら、時々刻々と変化する現実世界において人と多数の AI 群が同一環境で協働するためには、少なくとも大きく二点の問題点が存在する。一つ目は、多数の意思決定主体が同一環境中で目的を一つとして効果的に行動するには、個々のエージェントの局所的戦略と大域目標達成のための戦略を整合させる必要がある、そのための有効なメカニズムが明らかでない点である。二つ目は、人と AI 群が行う意思決定と行動の意図を相互に共有することが容易ではない点である。そのため、実用化されている自律システムのほとんどは、人と隔離した環境で協働する [Stentz 02] か、人によって遠隔操作を行うか [Balakirsky 07], 人とは異なる役割のみを予め明示的に割り当てて行う [Li 16] など、人同士に比べ協働は限定的である。

本研究では、動的に変化する切迫した対処すべき対象

が多数あり、少数の人間のみで対処することが困難な場面に対して人と AI 群がそれぞれ、同じ性能の身体性を持つエージェントにより対処を試みる状況を想定する。具体的な困難性の高い問題設定として、人と AI 群が協働するチーム（以下チーム A と呼ぶ）と、多数の人が操作する人エージェントのみによるチーム（同チーム B）に分かれて対戦形式で評価する鬼ごっこの環境を対象に、人と AI 群の協働を追求する取り組みを行った。提案するシステムでは、人と AI 群の戦略を整合させるためにマルチエージェント交渉技術を適用し、人-AI 間と AI-AI 間でフラットな合意形成を図るとともに、人と AI 群の間で意図や意向をタイムリーに共有する方法をプロトタイプングを通じて具体化した。

2. 問題の設定

本研究では、競争的かつ協調的要素を有する問題設定として、“しっぽ鬼”をチーム対戦形式で行うこととした。しっぽ鬼は幼児向けの遊びとして行われる鬼ごっこの一種であり、ズボンに挟んだ紐などをしっぽに見立てて、自身のしっぽは取られないようにしながら他のしっぽを取ることを狙うゲームである。遊びとしてのしっぽ鬼を念頭に、ネットワークを通じて多数の人が参加して対戦評

図1 しっぱ鬼のルール

図2 操作画面のイメージ (チーム A の人の画面)

価が可能なしっぱ鬼シミュレータを構築した。本研究で設定したゲームルールを図1に、操作画面のイメージを図2に示す。エージェントは2次元平面上の円形のフィールドにおいてチーム別に分かれ、左右各半分の領域内のランダムな位置からスタートする。エージェントは一人称の視野が前方に制限されるが、味方の他のエージェントの位置と向き、味方の誰かが観測している相手チームのエージェントの位置と向きは共有され、図2の画面右上の俯瞰情報表示に表示される。各エージェントは前進、後退、左右旋回ができ、人はゲームコントローラで操作し、AIも同じ性能で一つのエージェントを制御する。他のチームのエージェントの後方に接触すれば接触されたエージェントは退場となり、円形のエリア外に出た場合も退場となる。味方同士で密集するようなプレイを排除するため、同じチーム同士で接触すると一定時間フリーズするようにした。また、他のチームのエージェントと得失点条件以外で接触した場合も同様にフリーズする。

全てのエージェントの身体的能力は同一のため、局所的に1対1となった場合、互いに後方を狙ってぐるぐると周回したり、逃走する相手をいつまでも追いかける状況になり収束しない。このゲームにおける基本的な捕獲戦術は、局所的に数的優勢の状況を作り出し、相手にとにかく接触して一定時間フリーズの状態に持ち込んだ（以後、これを行うエージェントを足止め役と呼ぶ）うえで、その間に他のチームメイトが捕獲する（同捕獲役と呼ぶ）という役割分担のチームプレイが必要な問題設定となっている。役割分担に関わる意思疎通を行えるようにするた

め、チームBには音声チャット機能を付与し、同じチームのプレイヤー同士は音声による通信が行えるようにした。

本論文では、チームAの人を一人に限定し、他のエージェントを全てAI群とした。一方、チームBは全て人が操作するエージェントとして対戦評価を行うことで、チームAのチームとしての能力が人間によるチーム以上となるかを評価する。

3. 関連研究

自律エージェント間でチームワークを構築することは、マルチエージェントの主要な研究分野の一つである。例えばTambeは、チームワークの一般的なモデルとしてSTEAMを提案した[Tambe 97]。STEAMでは、チームワークの明示的なモデルとして、エージェントの組織階層と協調タスクを設計する。その際に重要な概念が役割である。役割とは、チームの全体的な活動のための個々あるいは部分的なチーム（サブチーム）が担う一連の行動セットに対する抽象的な仕様を示す。役割を各エージェントに割り当てるためには、タスクを適切なレベルの粒度に分解する必要がある。StoneらはRoboCupサッカーチームを例に、同種エージェントによるマルチエージェントタスクを柔軟な役割に分解するチームワーク構造例を提示した[Stone 99]。Stoneらの提案では、タスクを抽象化して表現した「役割」を一連の手続きとして事前に定義し、エージェント間でこれを「ロッカールーム合意」として共有しておくことにより、限定的な通信によって実用的な協調が実現可能なことを示した。

また、エージェント間でタスクや役割を分担するための割り当て調整メカニズムも必要となる。経済的な活動をモデルとした市場ベースの分散協調は分散アプローチの一つであり、マルチロボット協調の分野でも用いられている[Dias 06]。市場ベースの分散アプローチの基本的なモデルとして、Smithによって提案された契約ネット・プロトコル(CNP)[Smith 80]が挙げられる。CNPは人間社会の契約プロセスに由来し、エージェント間交渉により割り当て問題を解決しようとする際の通信内容を定めた分散問題解決のためのフレームワークである。

4. 提案システムのプロトタイプ

チームAの人とAI群が協働するにあたり、人-AI間とAI-AI間でフラットな合意形成を図るため、CNPを用いてエージェント間でタスクを調整できるようにした。また、AI群がブラックボックス方策を持つ場合、人から見てAI群の意図や意向を把握することが困難と考え、本研究ではBehavior Tree(BT)[Colledanchise 18]を用いてAIのふるまいを可視的に定義することとした。BTはAIのふるまいをツリー状に表現する手法で、階層的な意思決定を可視的に定義可能である。代表的なBTノードの

表 1 代表的な BT ノードの説明 [Colledanchise 18]

Node Type	Symbol	Succeeds	Fails	Running
Sequence		If all children succeed	If one child fails	If one child returns running
Fallback		If one child succeeds	If all children fail	If one child returns running
Action		Upon Completion	If impossible to complete	During completion
Condition		If true	If false	Never

図3 AI エージェントの行動モデルの BT

説明を表 1 に示す. BT と CNP を組み合わせることで, チーム A で協働する人間はチームメイトの個々の AI が時々刻々の瞬間に何をしようとしているか明確に把握しながらタスクを調整できる [Matsunami 20].

図3にAIエージェントの行動モデルのBTを示す。AIエージェントの実施するタスクの分類として協調タスクと個別タスクの二つを定義した。協調タスクは、エージェントが協調して実施する必要があるタスクとして定義し、CNPによる契約によって駆動される。一方、個別タスクは個々のエージェントの置かれている状況に応じて実施するタスクとして定義し、個々のエージェントの裁量によって実行される。

しかし、協調タスク中であっても、味方エージェントを不利な状況に追い込まないようにするため、タスク (1) : エリア逸脱回避や、タスク (2) : 衝突回避のように、安全性を確保するために必要な個別タスクは、協調タスク中であっても常に実行可能としている。

協調タスクとして集合、捕獲、搜索の三つのタスク仕様を設定し、タスク割り当てを CNP によって交渉できる。ここで、協調タスクを複数のエージェントで遂行するために個々のエージェントが担うべき一連の行動セットに対する抽象的な概念を役割と呼ぶ。例えば捕獲タスクの場合、フリーズしたターゲットを捕獲する捕獲役と、

ターゲットをフリーズ状態に持ち込む足止め役、足止めを支援するサポート役という三つの役割にタスクを分解した。また、ターゲットが反方位に逃げ続ける場合にはターゲットの移動範囲を制約しながら追いかける追跡役も定義した。このように、CNPによって協調タスクを実施するサブチームを構成し、サブチーム内の役割は一意に決定されるようにAIのふるまいを定義した。

本研究では、AI は短期的かつ局所的なタスクを得意とすると仮定し、AI-AI 間では協調タスクのうち捕獲タスクを近傍の AI エージェントと自律的に CNP により交渉を行うこととした。一方、人はより抽象的で大局的なタスクを得意とすると仮定し、捕獲に加えて探索と集合のいずれの協調タスクも CNP により交渉を行える。

作成したプロトタイプでは、図2のAIエージェント（青の人型）のように、頭上に実施中のBT分岐状況に対応したアイコンを表示することにより、一見してAIの意図が把握できるようにした。

5. 強化学習の試行

4章で述べたBTによって定義したプリプログラムのAI群に加え、深層強化学習を用いたエージェント行動の獲得も試行して、性能差や追加の課題の有無を検証した。

図4 セルフプレイ強化学習の設定

協働する人にとって理解可能な形で実現するため、強化学習の適用は捕獲タスクに絞って適用することとし、CNPによって協調して捕獲タスクを実施するサブチームが構成された場合にBTによって捕獲タスクが選択され、強化学習モデルを実行する。

3体のエージェントによる捕獲タスクの学習にはUnity ML-Agents [Juliani 18] と学習アルゴリズムとしてPPO (Proximal Policy Optimization) [Schulman 17] を用いた。また、捕獲目標の逃走エージェントの行動に多様性を持たせ捕獲タスクの成功率を上げるために、セルフプレイ強化学習 [Silver 18] を用いた。セルフプレイ強化学習とは、対戦型の学習環境において、対戦する双方のチームが交互に学習を行う強化学習手法の一つである。セルフプレイ強化学習では学習するチームをどのような比率で交代するかを決定する必要がある。本学習では、逃走エージェントは捕獲を免れるように逃走する行動を学習するのに対し、捕獲エージェントは他の捕獲エージェントと協力して逃走エージェントを捕獲する行動を学習する必要がある。捕獲エージェントの行動の方が学習難易度が高い。そのため、捕獲エージェントチームの学習頻度を大きくした。

図4に実施したセルフプレイ強化学習の設定を示す。捕獲エージェントには行動として自身の移動に加え捕獲役及び足止め役のどちらかを宣言させることとした。捕獲エージェントの観測は味方エージェントの宣言を加えた以下の16種類とした。

- 自身のフリーズ残り時間 (1 種類)
- 味方の捕獲エージェント 2 体の 2 次元相対位置・相対姿勢・フリーズしている場合のフリーズ残り時間及び宣言 (10 種類)
- 逃走エージェントの 2 次元相対位置・相対姿勢及びフリーズしている場合のフリーズ残り時間。但し、全ての捕獲エージェントが逃走エージェントを視野に入れていない場合は逃走エージェントを最後に観測した時点の値を入力 (4 種類)
- 逃走エージェントを最後に観測した時点からの経過時間 (1 種類)

捕獲エージェントの報酬として、「捕獲」を宣言して逃走エージェントを捕獲した場合、「足止め」を宣言して逃

走エージェントの足止めを行った場合、さらに足止め後に味方のエージェントが捕獲した場合に正の報酬を与えた。このように、捕獲エージェントが逐次何を意図して行動しているかを人間にとって理解可能な自律エージェントを構築した。逃走エージェントの行動は、捕獲エージェントの宣言を除いた移動のみとし、観測は以下の16種類とした。

- 自身のフリーズ残り時間 (1 種類)
- 捕獲エージェント 3 体の 2 次元相対位置・相対姿勢及びフリーズしている場合のフリーズ残り時間。但し、逃走エージェントが捕獲エージェントを視野に入れていない場合はその捕獲エージェントを最後に観測した時点の値を入力 (15 種類)

また、逃走エージェントの報酬は図4に示したように離隔 (逃走) に成功した場合は+1, 被捕獲時は -1 といったように付与した。このセルフプレイ強化学習の取組みにより、多様な逃げ方をする目標においても連携しながら捕獲を行う強化学習モデルを獲得した。

6. 実験

6.1 実験条件

構築したしっぽ鬼シミュレータを用いて評価を行った。試験ケース及び結果を表2に示す。但しあるチーム X のエージェント数を n_X , そのうち人エージェント数を n_X^h と表すものとする。試験に参加した人エージェントの操作者は、全て著者の勤務先の同じ職場のエンジニアであり、本プロジェクトに参加していない者とした。表2に示した全ての試験は、変動要素を最小化するため同一日に、条件を固定して3回ずつ行った。試験ケース No.1~No.3 はそれぞれ 10 対 10, 20 対 20, 30 対 30 の評価であり、チーム A において唯一の人エージェントを操作する評価者による個人差を極力排除するため、評価者 2 名を設定し各回ずつデータを取得した。No.4 は No.3 の結果と比較するため、30 対 30 かつ AI エージェントに 5 章で作成した強化学習モデルを適用したケースである。No.5 は No.3 の試験前にチーム B の参加者に対して慣熟を期すために 30 対 30 かつ $n_A^h = 0$ として実施したケース、No.6 は試験を経るごとにチーム B の参加者の技量が向上する可能性に鑑みて、全ての評価を実施した後に No.5 と同一の条件で行ったケースである。

6.2 結果

表2に示した結果のうち、平均捕獲率 (評価終了までに各チームが相手チームのエージェントを何%捕獲できたか) をグラフ化した結果を図5に示す。表2及び図5には、各チーム間の平均捕獲率に対し t 検定を行って、その p 値を示した。検定には、2 群間の平均値の差を比較するためパラメトリック検定の Welch [Welch 47] を用いた。図5の通り、No.1 のケースを除いてチーム A (人

表 2 実験ケース一覧, 結果及び t 検定の結果

No.	概要	n_A, n_B	n_A^h	n_B^h	チーム A 平均捕獲率	チーム B 平均捕獲率	p	所要時間 秒	サンプル数	チーム A 評価者数
1	10vs10	10, 10	1	10	76.7% (0.11)	60.0% (0.18)	0.45	185 (25.0)	6	2
2	20vs20	20, 20	1	20	100.0% (0.00)	41.7% (0.09)	0.0013*	198 (18.5)	6	2
3	30vs30	30, 30	1	30	100.0% (0.00)	38.9% (0.06)	0.00021**	253 (42.5)	6	2
4	30vs30 強化学習	30, 30	1	30	100.0% (0.00)	64.4% (0.10)	0.069	375 (93.8)	3	1
5	30vs30 慣熟	30, 30	0	30	100.0% (0.00)	43.3% (0.08)	0.021*	180 (3.8)	3	0
6	30vs30 評価後	30, 30	0	30	100.0% (0.00)	52.2% (0.06)	0.015*	193 (25.6)	3	0

備考: () 内は標準誤差を示す

*: $p < 0.05$, **: $p < 0.01$ (備考) n.s.: 非有意, *: $p < 0.05$, **: $p < 0.01$

図 5 捕獲率の比較

と AI 群が協働するチーム) がチーム B (全て人によるチーム) のエージェントを全て捕獲した. 提案手法である No.1,2,3 のケースのうち, No.1 以外でチーム A と B の平均捕獲率に有意差が確認された. No.1 のケースにおけるコーエンの効果量 [Cohen 88] は 0.50 で中程度であり, 有意水準 0.05, 検定力 0.8, 効果量 0.50 の場合のサンプルサイズが 63.8 である一方, 本実験のサンプル数は 6 とかなり差があるため, No.1 においてもチーム A の平均捕獲率はチーム B と比べて高い可能性はある.

チーム B の捕獲率は No.1,2,3 の比較で低下傾向であり, エージェント数に対するスケーラビリティでチーム B がチーム A に劣る可能性を示唆する. No.4 は No.3 と比較してチーム A の捕獲率は同じ 100% であるが, チーム B の捕獲率 (チーム A のエージェントが捕獲された割合) は増加しており, 強化学習によるエージェントを用いたチーム A よりも, プリプログラムによるエージェントの方が良い結果となった. No.3 と No.5, 6 の違いはチーム A に協働する人エージェントが存在するか否かであり, No.3 のチーム B の捕獲率が最も低くなっている. 提案システムによって人と AI 群が協働し, 少なくとも人によるチームと同程度かそれ以上の性能を発揮したといえる.

7. 考 察

チーム A に人エージェントが存在する場合 (No.1, 2, 3, 4) としない場合 (No.5, 6) の大きな違いは, 4 章で述

べたように搜索と集合の二つの協調タスクが行われるかどうかである. このうち搜索タスクの有無は, 今回の実験では双方が相手エージェントを積極的に捕獲しようと試みたため, ほとんどの場合容易に相手を発見でき, 結果に大きく影響しなかった. 一方集合タスクは, AI 群の塊が分離してしまったような場合に効果を発揮した. 図 6 に, ケース No.3 におけるエージェント位置の推移の例を示す. 図はゲームエリアを上から俯瞰した状況を示している. この例では, シミュレーション時間 72 秒時点ではチーム A は一群として行動していたが, 99 秒時点では二群に分離してしまっており, チーム A の人が分離した AI 群を呼び戻すべく集合タスクを依頼し, 151 秒付近にはチーム A を一群としてまとめることで数的優勢の状況を確認することに成功している. このように, AI 群の迅速な捕獲タスクの遂行だけでなく, 人による大局的な判断に基づく AI 群の集合タスクの両立により有利な状況を拡大できていた.

強化学習の適用 (No.4) では, No.3 の成績を上回ることとはなかったものの, 十分な成績 (捕獲率 100%) を示し, 強化学習の将来性を感じさせる結果となった. 可読性のないブラックボックス方策を持つ強化学習モデルは, 人との協働において大きな制約があると考えられるが, 本提案のようにチームとして実施するタスクを個別タスクと協調タスクとして定義し, 役割分担に分解したうえでその範囲内の行動を学習で獲得させ, 実行時にはどの役割を行っているかを表明させることにより, 人と協働が可能であることを示した. 但し, チーム A 評価者に対する実験終了後のインタビューにおいて「強化学習モデルでは同じ相手に何回もぶつかる挙動不審な AI がいた」といった意見があったように, 人間が疑問に思う行動も存在したことなど, さらに改善すべき課題も存在する.

8. ま と め

本研究では, 動的に変化する切迫した対処すべき対象が多数あり, 少数の人間のみで対処することが困難な場面を想定したチーム形式のしっぽ鬼を例題として取り上げ, 相手を捕獲するためには協力が必要な問題設定とした. 例題に対してチームワークを実現するためのタスク仕様と役割を設定して可読性の高い Behavior Tree により定義し, 契約ネット・プロトコルで分散的にタスクと

図 6 実験ケース No. 3 における集合タスク実施例

役割を分担できるシステムを構築した。提案システムを用いて 10~30 人で構成される多数の人によるチームを対戦相手とし、一人の人が同一の身体性を持つ AI 群と協働して、同程度かそれ以上の対処が可能なことを示した。

一方、本研究では個々の AI エージェントの意図は把握できるようにしたもの、AI 群としての集合的意図の人との共有や、AI 群と協働する人が複数となった場合の人群内及び人群-AI 群間の協働のあり方は未解決である。また、今回の実験ではチーム A において AI と協働する人はエンジニアを被験者としたが、エンジニア以外の多様な背景を持つ一般の被験者による場合、システム慣熟に要する期間やチーム A のパフォーマンスがどの程度影響を受けるか、後続研究による検証が望ましい。これらを踏まえ、社会応用に向けて引き続き検討を行っていく。

謝 辞

本研究は、防衛装備庁の安全保障技術研究推進制度 (JPJ004596) の支援を受けたものである。

◇ 参 考 文 献 ◇

- [Balakirsky 07] Balakirsky, S., Carpin, S., Kleiner, A., Lewis, M., Visser, A., Wang, J., and Ziparo, V. A.: Towards heterogeneous robot teams for disaster mitigation: Results and performance metrics from RoboCup Rescue: field reports, *J. Field Robot.*, Vol. 24, No. 11-12, pp. 943-967 (2007)
- [Cohen 88] Cohen, J.: *Statistical Power Analysis for the Behavioral Sciences*, Lawrence Erlbaum Associates (1988)
- [Colledanchise 18] Colledanchise, M. and Ogren, P.: *Behavior Trees in Robotics and AI: An Introduction*, CRC Press (2018)
- [Dias 06] Dias, M. B., Zlot, R., Kalra, N., and Stentz, A.: Market-based multirobot coordination: A survey and analysis, *Proceedings of the IEEE*, Vol. 94, No. 7, pp. 1257-1270 (2006)
- [Juliani 18] Juliani, A., Berges, V., Vckay, E., Gao, Y., Henry, H., Mattar, M., and Lange, D.: Unity: A general platform for intelligent agents, *CoRR*, Vol. abs/1809.02627 (2018)
- [Li 16] Li, J.-t. and Liu, H.-j.: Design optimization of amazon robotics, *Automation, Control and Intelligent Systems*, Vol. 4, No. 2, pp. 48-52 (2016)
- [Matsunami 20] Matsunami, N., Ito, M., and Karakama, S.: Architecture and interface for collaborating with a group of agents in an adversarial game, in *9th International Congress on Advanced Applied*

Informatics IIAI AAI (2020)

- [Schulman 17] Schulman, J., Wolski, F., Dhariwal, P., Radford, A., and Klimov, O.: Proximal policy optimization algorithms, *CoRR*, Vol. abs/1707.06347 (2017)
- [Silver 18] Silver, D., Hubert, T., Schrittwieser, J., Antonoglou, I., Lai, M., Guez, A., Lanctot, M., Sifre, L., Kumaran, D., Graepel, T., Lillicrap, T., Simonyan, K., and Hassabis, D.: A general reinforcement learning algorithm that masters chess, shogi, and Go through self-play, *Science*, Vol. 362, No. 6419, pp. 1140-1144 (2018)
- [Smith 80] Smith, R. G.: The contract net protocol: High-level communication and control in a distributed problem solver, *IEEE Transactions on Computers*, Vol. C-29, No. 12, pp. 1104-1113 (1980)
- [Stentz 02] Stentz, A., Dima, C., Wellington, C., and Stager, D.: A system for semiAutonomous tractor operations, *Autonomous Robots - AROBOTS*, Vol. 13, pp. 87-104 (2002)
- [Stone 99] Stone, P. and Veloso, M.: Task decomposition, dynamic role assignment, and low-bandwidth communication for real-time strategic teamwork, *Artificial Intelligence*, Vol. 110, No. 2, pp. 241-273 (1999)
- [Tambe 97] Tambe, M.: Towards flexible teamwork, *J. Artif. Int. Res.*, Vol. 7, No. 1, pp. 83-124 (1997)
- [Welch 47] Welch, B. L.: The generalization of 'student's' problem when several different population variances are involved, *Biometrika*, Vol. 34, No. 1/2, pp. 28-35 (1947)

[担当委員：高野 雅典]

2021 年 4 月 23 日 受理

著 者 紹 介

松波 夏樹(正会員)

1998 年神戸大学工学部電気電子工学科卒業。2000 年同大学院自然科学研究科電気電子工学専攻修士課程修了。同年、三菱重工業(株)入社。現在、人工知能応用システムの研究開発に従事。

唐鎌 聡太郎

2013 年東京工業大学工学部機械宇宙学科卒業。2015 年同大学院理工学研究科機械宇宙システム専攻修士課程修了。同年、三菱重工業(株)入社。現在、人工知能応用システムの研究開発に従事。