

令和6年度地球観測技術等調査研究委託事業
「高大連携宇宙 AI コンペティションを通じた
「インテリジェント宇宙機」開発人材の育成」
委託業務成果報告書

令和7年5月
国立大学法人金沢大学

本報告書は、文部科学省の地球観測技術等調査研究委託事業による委託業務として、国立大学法人金沢大学が実施した令和6年度「高大連携宇宙 AI コンペティションを通した「インテリジェント宇宙機」開発人材の育成」の成果を取りまとめたものです。

目次

1	はじめに.....	1
1.1	委託業務の目的.....	1
1.2	業務の方法.....	1
1.3	当該年度における委託業務の結果概要.....	1
2	実施内容.....	3
2.1	「AI 教育用衛星システム」を用いたオンボード AI の実装と評価.....	4
2.1.1	オンボード AI モデルの搭載実習.....	4
2.1.2	自律性能評価実習.....	14
2.2	自発的な研究活動等.....	23
3	まとめ.....	24
4	添付資料.....	27

1 はじめに

1.1 委託業務の目的

本業務の目的は、来る Society 5.0 時代における宇宙機運用の形として「オンボード AI による自律運用」をテーマに挙げ、それを実現するための技術を備えた人材を「高大連携宇宙 AI コンペティション」によって発掘・育成することである。大学や民間による超小型衛星開発や衛星コンステレーション実現の動向を踏まえると、マンパワーに頼った古来の衛星運用の形態にはいずれ限界が訪れる可能性がある。人工知能(AI)は、衛星運用が抱えるこれらの課題を解決する手段となり得るが、宇宙科学の難解さや専門性の高さに加え、衛星運用・観測データのオープン化が遅れていることから、AI 技術の応用先としては黎明期である。本業務では、金沢大学が所有する過去 30 年間分の衛星運用・観測データを活用したコンペティションを開催し、情報分野を得意とする高校生～大学院生から潜在的な宇宙 AI 人材を発掘する。また、大学院生による「AI 教育用衛星システム」の開発と連動することで、自身のモデルで宇宙機を制御する経験を通し、宇宙への興味と関心を引き出す。

1.2 業務の方法

令和6年度における実施内容は、以下の通りである。

①「AI 教育用衛星システム」を用いたオンボード AI の実装と評価

a. オンボード AI モデルの搭載実習

前年度までの AI コンペティションで優秀な成果を残した独自 AI モデルの実機搭載実習を、ワークショップやコンペティションに携わった大学生・大学院生を中心として行う。宇宙環境を模擬した動作確認試験を通して、自身が開発した AI モデルで宇宙機を制御する様子を体験し、宇宙 AI 開発の実務経験を備えた宇宙職業人としての素質を身に付ける。

b. 自律性能評価実習

独自 AI モデルの改良を通して、オンボード AI デバイス上で実現するタスクの性能向上を図り、具体的な観測課題の達成精度を数値的に評価する。実習実施前後で教育的効果を測るアンケート調査を行い、全項目が向上することを達成目標とする。また、進学・就職先のジャンルや修士・博士課程進学意欲の変化に関する調査を行う。

②自発的な研究活動等

自発的な研究活動等に関する実施方針に基づき、所属機関が認めた範囲で自発的な研究活動等を推進する。

1.3 当該年度における委託業務の結果概要

令和6年度における業務の結果概要は、以下の通りである。

①「AI 教育用衛星システム」を用いたオンボード AI の実装と評価

a. オンボード AI モデルの搭載実習

前年度までの AI コンペティションで優秀な成果を残した独自 AI モデルの実機搭載実習を、ワークショップやコンペティションに携わった大学生・大学院生を中心として行った。宇宙環境を模擬した動作確認試験を通して、自身が開発した AI モデルで宇宙機を制御する様子を体験し、宇宙 AI 開発の実務経験を備えた宇宙職業人としての素質を身に付けさせた。

b. 自律性能評価実習

独自 AI モデルの改良を通して、オンボード AI デバイス上で実現するタスクの性能向上を図り、具体的な観測課題の達成精度を数値的に評価した。実習実施前後で教育的効果を測るアンケート調査を行い、全項目が向上することを達成目標とした。また、進学・就職先のジャンルや修士・博士課程進学意欲の変化に関する調査を行った。

②自発的な研究活動等

自発的な研究活動等に関する実施方針に基づき、所属機関が認めた範囲で自発的な研究活動等を推進した。

2 実施内容

近年、機械学習技術は画像認識、音声処理、需要予測、故障検知といった多岐にわたる分野での応用が進んでいる。その背景には、ニューラルネットワークにおける膨大な計算が、GPU (Graphics Processing Unit) によって高速で処理可能となったことが挙げられる。科学分野では、機械学習技術を科学衛星上でのエッジコンピューティングに応用する取り組みが注目されている。エッジコンピューティングとは、データを収集する端末やセンサの近傍に情報の保存場所と計算能力を配置したプロセスのことで、クラウドを介さずにデータをその場で分析できるため、通信負荷を低減し、処理のリアルタイム性を確保することができる。科学衛星を用いた観測では、計算リソースと通信リソースが限られており、機上の小型コンピュータでデータの前処理や圧縮を実施し、質を維持しながらデータサイズを削減することが求められる。例えば、ジオスペース探査衛星「あらせ」や水星磁気圏探査機「みお」では、CPU (Central Processing Unit) を用いた信号処理やパターンマッチング処理が実装され、科学的価値の高いデータが優先的に地上へ送信する工夫がされており、観測データのリアルタイム処理や送信データ量の削減が可能となり、限られたネットワークリソースの効率的利用を支えてきた。しかし、このような従来の技術は、事前にプログラムされた処理に依存しており、データの内容に応じた柔軟な判断や高度なパターン認識を実現するには不十分である。科学衛星上で機械学習モデルによる推論ができれば、観測データの自動分類や特徴量の自動抽出が実現できるようになり、サイエンスアウトプットの大幅な向上が期待できる。

本研究チームを構成するメンバは、科学衛星を用いた宇宙からの多種多様な観測や、地上に設置した光学装置等によるリモートセンシングなどを、30 年以上に渡って実施してきた。本研究課題では、これらの宇宙ビッグデータを活用したデータ解析ワークショップおよびコンペティションの開催を通じて宇宙ビッグデータを活用できる人材の育成を目指すとともに、オンボード AI 推論を実現するための次世代オンボードコンピュータ(AI-OBC)の開発を大学生・大学院生と共に行い、将来の超小型衛星ミッションのインテリジェント化に貢献する。本委託業務の実施スケジュール(実績)を表 1 に示し、個々の実施項目について次節以降で述べる。

表 1 本委託業務の実施スケジュール(実績)

実施項目	4	5	6	7	8	9	10	11	12	1	2	3
令和 6 年度												
① 「AI 教育用衛星システム」を用いたオンボード AI の実装と評価 (2.1)												
a. オンボード AI モデルの搭載実習 (2.1.1)												
実習前アンケート実施①	↔											
大学(院)生によるオンボード AI の実装		←										
大学(院)生によるオンボード AI の評価								←				
実習後アンケート実施①												↔
実習前アンケート実施②						↔						
高専生によるオンボード AI の実装					↔							
高専生によるオンボード AI の評価					↔							
実習後アンケート実施②						↔						
Web ページ保守	←											→
b. 自律性能評価実習 (2.1.2)												
実習前アンケート実施③						↔						
モデル評価演習								←				
実習後アンケート実施③												↔

2.1 「AI 教育用衛星システム」を用いたオンボード AI の実装と評価

2.1.1 オンボード AI モデルの搭載実習

令和 5 年度に開発した衛星搭載用のオンボード AI デバイス(AI-OBC, 図 1)を中心とした「AI 教育用衛星システム」を用いて, 金沢大学の大学生および大学院生がオンボード AI モデルの実装と評価を行った(図 2). AI-OBC は AI アクセラレータを備えた動的再構成プロセッサをメインプロセッサとして搭載している. 本事業では AI-OBC 上で動作する深層学習モデルを 3 種類実装し, その推論性能を評価した. 図 3, 図 4, 図 5 に, 実装したモデルの構造を示す. このうち 図 4(ResNet50)と, 図 5(YOLOv3)は, いずれも画像認識や物体識別に広く用いられるモデルである. これらのモデルで CIFAR-10 データセットの学習を行い, 推論を AI-OBC で行った結果を検証した. 図 6 は結果の一例であり, 図 3 のモデルによって CIFAR-10 データセットが高い精度で分類されていることが分かる. このときの推論速度は 1858 us/image であった. 同じモデルを Xilinx 社製 Zynq-7000 SoC の CPU を用いた推論速度と比較したところ, AI-OBC は Zynq-7000 SoC の CPU に対して約 867 倍高速に推論できることを確認した.




図 1 AI-OBC(ブレッドボードモデル)




図 2 AI-OBC(ブレッドボードモデル)を用いた開発の様子




図 3 検証した畳み込みニューラルネットワークモデルのモデル構造




図 4 検証した ResNet50 のモデル構造




図 5 検証した YOLOv3 のモデル構造




図 6 畳み込みニューラルネットワークモデルによる CIFAR-10 の推論結果

AI-OBC と他の代表的なデバイスで、機械学習モデルによる推論を行う際の推論精度、推論速度、電力効率を比較し、科学衛星への搭載可能性を評価した。比較対象には、FPGA(Field Programmable Gate Array)による処理を検証するためにPYNQ-Z2を用い、CPUによる処理を検証するために、Raspberry Pi 4 Model Bを用いた。また、GPUによる処理を検証する際は、NVIDIA 社製 Tesla V100を使用した。PYNQ-Z2 は、Xilinx 社製 Zynq-7000 SoC を搭載した TUL 社製の組み込みシステム評価ボードである。Zynq-7000SoC には、ARM Cortex-A9 プロセッサと Xilinx 社製の Artix-7 FPGA が内蔵されている。これらを用いて、図 4 や図 5 で示したモデルを用いて評価を行った。推論速度はテストデータ 10000 枚を使用して測定した。推論時間にはデータ伝送遅延などにより外れ値が発生することがあるため、これを四分位範囲(Interquartile Range; IQR)を用いて判定し、除去する。具体的には、第 1 四分位数から IQR の 1.5 倍を下回る推論速度、または第 3 四分位数から IQR の 1.5 倍を超える推論速度を外れ値として判定し、これらを除いた後に平均を算出して推論速度を評価する。推論速度の単位として、1 秒間に処理可能な画像枚数を示す image/s を採用する。GPU では、バッチ処理が可能であるため、テストデータに対する推論速度は、バッチ単位の処理時間をバッチサイズで除算することで 1 枚あたりの推論速度を求める。各バッチに対して画像 1 枚あたりの推論速度を計測し、全体のテストデータ (10,000 枚) に対するバッチごとの平均推論速度を算出する。また、GPU の処理では CPU とメモリを他のプロ

セスと共有するため、推論速度にばらつきが生じることがあり、IQR に基づいて外れ値を除去し、平均値を算出する。

表 2 は、図 3 の機械学習モデルを用いて各デバイスの処理性能比計測した結果である。AI-OBC (DRP) で機械学習モデルによる推論を行った際の推論精度は、FPGA で行う場合より 0.13% 高かったが、CPU や GPU で行う場合に比べ 5.8% 低かった。この結果は、各デバイスが使用する演算方式の違いに起因すると考えられる。

AI-OBC は機械学習モデルによる推論処理に 16 ビット浮動小数点数 (以下、FP16) を用いた演算を採用しているのに対し、CPU や GPU では 32 ビット浮動小数点数 (以下、FP32) を用いた演算が行われる。機械学習モデルによる推論では、モデルの重みや活性化関数のパラメータが最適な予測を行うために細かく調整されている。

FP16 は FP32 と比較して表現可能な数値の精度が低く、同一のモデルを AI-OBC で動作可能な形式に変換する際、FP16 への丸め込み処理が行われる。これにより、AI-OBC で機械学習モデルによる推論を行う際に誤差が生じ、推論精度が低下していると考えられる。同様に、FPGA は二値化演算を採用しており、モデルのパラメータを 0 または 1 に限定しているため、機械学習モデルによる推論を行う際に生じる誤差が大きく、推論精度に与える影響がさらに大きくなっていると考えられる。

AI-OBC で機械学習モデルによる推論を行った際の電力効率は、CPU での推論時に比べて 20.3 倍高く、GPU での推論時に比べて 1.57 倍高かった。AI-OBC は FP16 での演算を採用することにより推論速度を向上させると同時に、動的再構成というハードウェアアーキテクチャを用いることで消費電力を抑えている。CPU では機械学習モデルによる推論を行う際の消費電力は AI-OBC での推論時とほぼ同等であった。しかし、CPU による推論処理時には FP32 での演算が行われており、FP16 に比べて計算量が増加していることと、CPU はシングルスレッド処理に特化しており、大規模な並列計算が必要な機械学習の推論処理には向いていないことから、CPU での機械学習モデルによる推論時間が長くなり、結果的に電力効率が AI-OBC より低くなったと考えられる。GPU は大量の演算ユニットを持ち、大規模な並列処理を得意とするため、機械学習モデルによる推論を行う際の推論速度は AI-OBC での推論時と比較して 75.89 倍高速であったが、演算ユニットを大量に動作させるため、消費電力が大きくなり、結果的に電力効率が AI-OBC より低下することが分かった。これらの結果から、電力効率の観点では、AI-OBC が CPU や GPU より優れていることが示された。FPGA で機械学習モデルによる推論を行う際の電力効率は、AI-OBC での推論時に比べて約 2 倍高かった。この結果は、FPGA は二値化演算を採用することにより、計算負荷を大幅に軽減していることに起因する。また、AI-OBC と FPGA のハードウェアロジックを比較すると、AI-OBC は推論処理中に回路を動的に再構成する機能を有しているが、この再構成には一定の時間がかかる。一方で、FPGA は推論処理に特化した回路をハードウェアレベルで設計することができ、予め設計した回路を使用して演算を行うため、推論処理中に回路の再構成を必要せず、再構成によるオーバーヘッドが発生しない。そのため、FPGA は二値化演算による計算負荷の軽減と、特化型回路による効率的な推論処理により、AI-OBC と比較して電力効率において優れた性能を示したと考えられる。

AI-OBC は動的再構成により消費電力を抑えつつ、推論処理に FP16 での演算を採用することで推論精度と推論速度を最適化している。CPU や GPU は FP32 での演算を採用することで高い推論精度を実現している反面、CPU では推論速度の低下、GPU では消費電力の増加というデメリットがある。FPGA はハードウェアロジックにより高い推論速度を実現しているが、二値化に伴う情報の損失が推論精度に影響を与えている。これらの結果から、AI-OBC は推論精度と電力効率のバランスにおいて優れた性能を示しており、科学衛星のようなリソース制

約のある環境においては, AI-OBC による推論性能が有用であると考えられる. また, AI-OBC は動的再構成によって, 大規模なモデルの実装を可能としている.

表 2 デバイスごとの推論性能評価

デバイス	推論精度 (%)	推論速度 (image/s)	電力効率 (image/(s·W))
DRP	79.10	387.23	153.67
FPGA	78.97	631.71	315.86
CPU	84.90	17.41	7.57
GPU	84.90	29385.84	97.95

これらの特性を活用し, 推論精度の向上を目的として ResNet18 および ResNet50 を AI-OBC 上に実装した. これらのモデルは, 従来の CNN モデルと比較してより深い層を持ち, 複雑な特徴を学習する能力が向上しているため, 推論精度の向上が期待される. 表 3 に, デバイス毎の ResNet18 と ResNet50 モデルの推論精度と電力効率を示す. AI-OBC で ResNet18 および ResNet50 の両モデルによる推論を行った際の推論精度は 85%に達した. さらに, 前節で示した CNN モデルと比較して 6%の精度向上を実現した. AI-OBC は動的再構成により, リソースの消費が多い ResNet18 および ResNet50 モデルを実装できる. 一方, FPGA 上では, リソース制約を理由としてこれらのモデルを実装することが不可能であった. FPGA では, 二値化ニューラルネットワーク(Binary Neural Network; BNN) を実行するために BNN-PYNQ パッケージを使用した. BNN-PYNQ パッケージとは, Xilinx 社が開発した FPGA 上で BNN を動作可能にするパッケージである. このパッケージでは, 各畳み込み層の演算を専用のハードウェア回路として個別に実装するため, FPGA 内のリソース(LUT (Look-Up Table), ブロック RAM)が大量に消費される. その結果, FPGA 上では畳み込み層を最大 14 層までしか実装することができず, ResNet50 のような畳み込み層を多用するモデルを構築することができなかった. CPU, GPU で ResNet18 モデルによる推論を行った際の推論精度は 94.72%, ResNet50 モデルによる推論精度は, 95.30%であった. AI-OBC で推論を行った際の推論精度は, CPU や GPU と比較して, ResNet18 モデルの場合は 9.5%低く, ResNet50 モデルの場合は 10.34%低かった. この精度低下の原因については, AI-OBC と CPU および GPU 間での演算方式の違いが影響していると考えられる. 本節では, ResNet18 モデルと ResNet50 モデルで, CIFAR-10 を分類するタスクを設定したが, GPU で両モデルによる推論を行った際の推論精度はほぼ等しかった. これは, CIFAR-10 を分類するタスクに対しては ResNet18 モデルの複雑さで十分であったことを示している. また, AI-OBC で ResNet18 および ResNet50 の両モデルによる推論を行った際の電力効率は, CPU で推論を行った際より約 26 倍高かった. ResNet18 および ResNet50 を AI-OBC 上に実装した結果, AI-OBC は精度と電力効率, リソース効率のバランスにおいて優れた性能を発揮していることが示された. 特に, ResNet50 のような大規模モデルを科学衛星向けデバイスに搭載可能とした点は, AI-OBC は科学衛星のような制約の多い環境においても, 高精度かつ効率的な機械学習モデルの推論を実現できる可能性を示している.

表 4 デバイスごとの推論性能評価(ResNet18, ResNet50)

デバイス	ResNet18		ResNet50	
	推論精度 (%)	電力効率 (image/(s·W))	推論精度 (%)	電力効率 (image/(s·W))
DRP	85.21	32.65	84.96	13.55
FPGA	—	—	—	—
CPU	94.72	1.13	95.30	0.52
GPU	94.72	80.36	95.30	30.27

大学生・大学院生によるAIモデル搭載実習の結果を踏まえ、高校生・高専生向けのオンボードAIモデルの搭載実習として、2024年9月10日に香川高等専門学校高松キャンパスにて第6回AI-STEPワークショップを開催した(図8)。本ワークショップでは、ワークショップの趣旨に照らして特に高い興味を示した7名の高校生・高専生を集め、令和5年度に開催した第2回AI-STEPコンペティションの課題(土地利用土地被覆図の再現)を用いて、オンボードAIモデルの設計・実装に関する実習を行った。また、各自が作り上げたAIモデルを組み込み向けエッジデバイスに搭載し、限られたリソース環境下でのエッジコンピューティングの体験を通して宇宙におけるAI利用の有効性と課題点を参加者自らで考え、解決する取り組みを行った(図9左上:参加者が各自のAIモデルを構築し、AIモデルの学習を行う様子、同右上:ワークショップ内で用いたオンボードエッジデバイスの一例、同左下および右下:参加者がオンボードエッジデバイスにモデルを組み込み、動作確認を行う様子)。

土地利用土地被覆図の再現にあたっては、だいち(ALOS)で撮影された多波長合成画像データを分析して、石川県の土地利用土地被覆図の再現度を競う課題を設定した。学習には、福井県の多波長合成画像データを32×32 pixelでグリッド化した画像(約44000枚)と、各画像について土地利用土地被覆図に基づいてラベリングしたラベルデータを用意した。ラベルは「裸地(bare)」「人工構造物(built-up)」「耕作地(cropland)」「森林(forest)」「草原(grassland)」「水田(paddy field)」「海(water bodies)」の7種類とし、本来の土地利用土地被覆図で詳細に分類されている針葉樹林や広葉樹林等のクラスは、課題設定の簡素化のために森林のクラスにまとめるなどの工夫を行った。また、7種類のクラス間で学習データ数を不均衡とすることで、不均衡データセットに対して効果的な訓練方法を、参加者自身が工夫することを狙った。石川県の土地利用土地被覆図の再現には、だいちで撮影された多波長合成画像データを32×32 pixelでグリッド化した画像(約41000枚)を用いた。第1回AI-STEPコンペティションと同様に、参加者は学習用データセットを用いて独自のAIモデルを作成・訓練し、未分類データセットの分類に挑戦してその結果をAI-STEP Portalから提出する形式とした。

参加者は令和4年度に構築した宇宙・AI学習教材に基づいて宇宙ビッグデータの特性を理解し、各自のコンピュータ上でそれらを扱うAIモデルの構築に取り組んだ。取り組みには金沢大学・石川工業高等専門学校・福井大学から計4名の専門家がアドバイザーとして携わり、効果的なAIモデル構築に向けた助言や技術指導を行った。その後、参加者自らが構築した学習済みAIモデルを、衛星搭載コンピュータを模擬したRaspberry Pi 4(Google Coral USB Accelerator)に搭載する方法を学び、エッジ環境における推論性能の向上に向けた改良や、環境由来の制約の理解を深めた。参加者らが構築したAIモデルはAI-OBCでも動作させることを示し、参加者らに宇宙におけるAI利用の方法を学ぶ機会を提供した。

AI × 宇宙技術教育プログラム

AI-STEP

AI × Space Technology Education Program

第6回 AI-STEPワークショップ

2024年9月10日 (火) 10:00~16:40

会場：香川高等専門学校高松キャンパス (情報基盤センター 第一演習室)

AI を作ってみよう！
AI-STEP
ワークショップ



AI を作るなんて難しそう ...
そんなことはありません！
みなさんと一緒に、たった
1日で AI を作ってみよう！

タイムスケジュール

- 09:00-09:30 集合 (情報基盤センター 第一演習室)
- 10:00-11:30 ワークショップ パート1 (概要説明, AI-STEP特別講義の復習)
- 12:30-13:30 ワークショップ パート2 (AIモデルを理解する)
- 13:40-14:30 ワークショップ パート3 (AIモデルを改良する)
- 14:40-15:10 宇宙科学に関するミニ講義
- 15:10-16:30 ワークショップ パート4 (AI-STEPコンペティションの体験)
- 16:40 解散

申し込み方法

AI-STEP Portal の専用申込フォームからお申し込みください **【8月27日 (火) 締切 事前登録必須】**
AI-STEP Portal へのアクセスには、事前に利用登録 (無料) が必要です。

詳しい情報や参加登録はWebサイトから！
<https://ai-step.ec.t.kanazawa-u.ac.jp>



AI×宇宙技術教育プログラム「AI-STEP」事務局
メールでのお問い合わせ: info@ai-step.ec.t.kanazawa-u.ac.jp
電話でのお問い合わせ : 076-234-4874 (代表：船田)

図 7 第 6 回 AI-STEP ワークショップの案内リーフレット



図 8 第 6 回 AI-STEP ワークショップの様子



図 9 第 6 回 AI-STEP ワークショップでの AI モデル組み込み実習の様子




図 10 第 3 回 AI-STEP コンペティション課題(土地利用土地被覆図の解説)

第 6 回 AI-STEP ワークショップの参加者に対して、参加前後で興味や理解度を測るアンケート調査(5 段階で回答)を実施し、オンボード AI モデル搭載実習による教育効果を評価した(図 11)。AI に対する興味や、自ら AI を構築することに関するモチベーション(Q1, Q2)は、実施前後で大きな変化が見られないが、これは第 6 回

AI-STEP ワークショップの参加者を募った際に、宇宙ビッグデータを用いた AI モデリングおよび組み込み実習に興味がある学生に限定したためであると考えられる。AI の仕組みや応用に関する理解度(Q3, Q4, Q5, Q6)の大幅な向上が認められ、特に宇宙ビッグデータを対象とした AI モデルの構築に関する理解度(Q6)の向上が顕著であることが認められる。また、「ワークショップを通じて、AI や宇宙分野に関連した進路(AI や宇宙技術を学べる大学への進学, AI や宇宙技術を取り扱う企業への就職)への関心が変化したか」についてもアンケート調査を行った(関心が増した/やや関心が増した/変わらない/やや関心が薄れた/関心が薄れた の 5 段階回答)。その結果、全 7 名の参加者中 4 名が最高評価に相当する「関心が増した」を選択しており、本事業が宇宙 AI 人材の発掘と教育の両面で効果的に働いたことが示された(そのほかの回答は、「変わらない」「関心が薄れた」「未回答」が 1 名ずつであった)。演習の満足度については、7 名中 5 名が最高評価の「良い」と回答した(そのほかの回答は、「やや良い」「未回答」が 1 名ずつであった)。

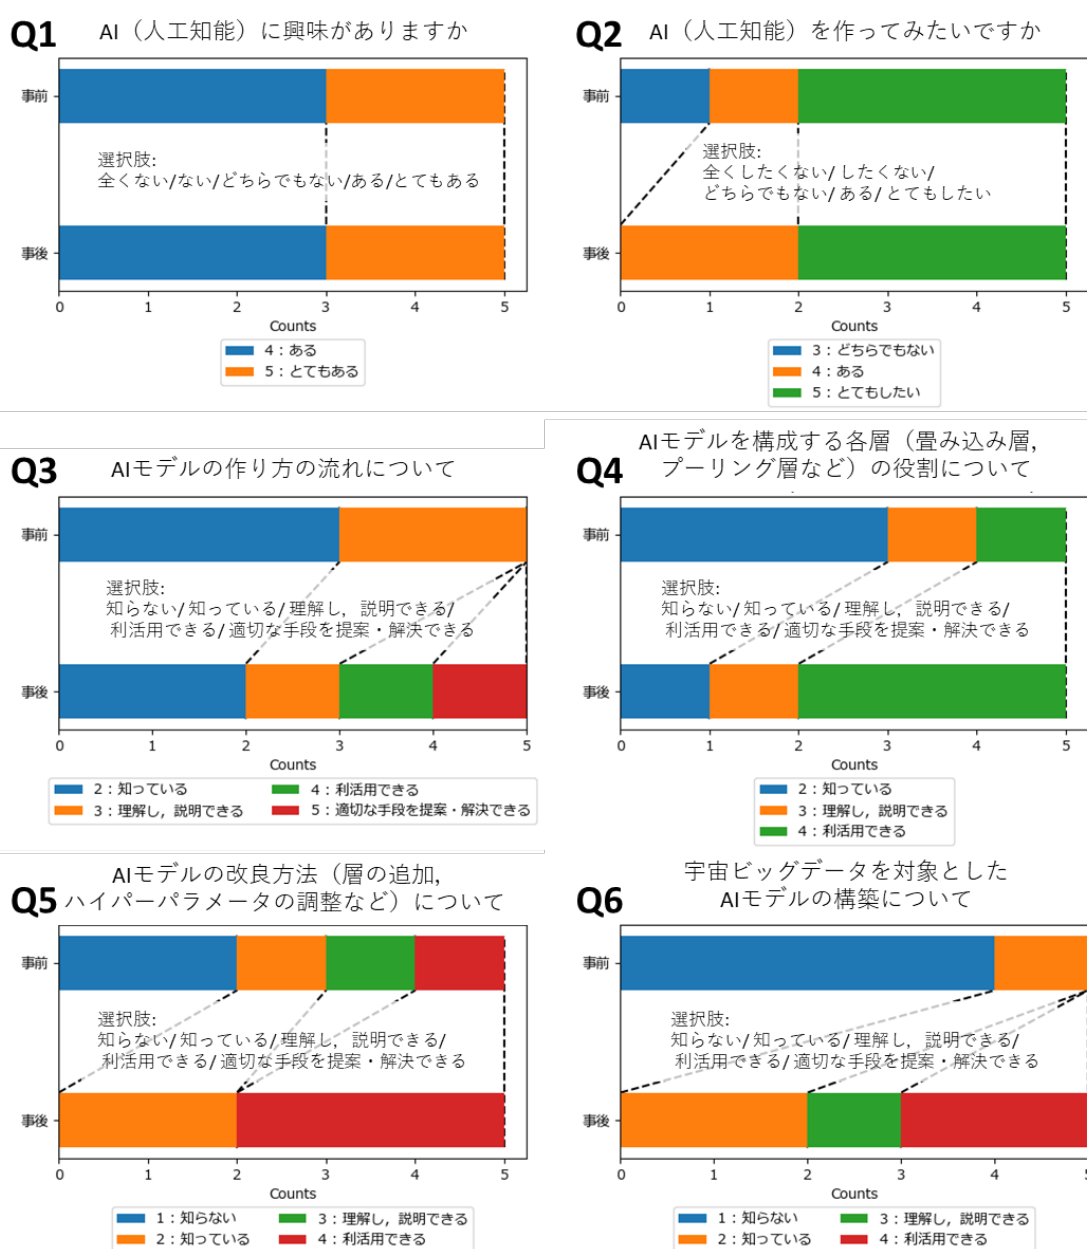


図 11 第 6 回 AI-STEP ワークショップの事前・事後アンケート結果

2.1.2 自律性能評価実習

金沢大学理工研究域電子情報通信学類および自然科学研究科電子情報通信学専攻の学生計 7 名に対し、2024 年 11 月から 2025 年 2 月の約 4 か月間に渡って、オンボード AI モデルの自律性能評価実習を実施した。オンボード AI モデルによる衛星システム制御の一例として、軌道上における温度環境変化に対して自律的にヒータ制御を行う熱制御系システムを開発した。一般的な人工衛星では、白金センサ等の温度計測系で計測した温度を元に、閾値を上回るか否かでヒータの駆動状態を変更させる二値制御則、または 2 種類の閾値を用いるヒステリシス制御則を採用している。しかしながら、これらの単純な制御則では、搭載機器の意図しない電源断などのイレギュラーな温度変化に対して、衛星搭載蓄電池に蓄えた電源を過度に消耗するような望ましくないヒータ制御をもたらす可能性がある。その結果、衛星搭載蓄電池の残量低下に伴う衛星機能停止や、それによる更なる温度低下を招く恐れがある。本実施項目では、金沢大学の大学生を中心として、オンボード AI によって最適なヒータ制御パターンを導き出すモデルを構築するとともに、その性能を評価することを目標として実習計画を立て、実施した。

温度制御を行う AI モデルを構築するため、コンピュータシミュレーションによって理想的な温度推移を表現して学習用データとして用いた。温度制御範囲を $[-20, +40^{\circ}\text{C}]$ とし、4 つの温度計測点のうち 1 点の目標温度を $+25^{\circ}\text{C}$ として、それを維持する最適なヒータ制御パターンを学習した。軌道上における衛星の充放電サイクルを考慮するため、地球低軌道(高度 550km)における日陰・日照パターンで衛星搭載蓄電池の蓄電量を制御した。これらの条件下で、AI-OBC に搭載した AI モデルによって種々の条件下でヒータ制御パターンを推論した。




図 13 は従来の閾値制御(ルールベース処理)に基づく制御の結果であり、図 14 は AI-OBC によるオンボード AI モデルを用いた制御の結果である。図中の赤線は目標温度($+25^{\circ}\text{C}$)であり、青線がヒータ制御による実際の温度推移である。背景の赤・青の帯は、それぞれ衛星の日照・日陰の時間帯を示す。本実験では、搭載機器の意図しない電源遮断を模擬して衛星内温度の急激な低下を再現し、その環境下での温度制御の結果を示している。結果を比較すると、従来の閾値制御では温度制御範囲下限(-20°C)を下回る時間帯が多くあるのに対し、オンボード AI モデルを用いた制御ではその間が短縮されていることが分かる。また、目標温度への最終的な到達時間も短縮されており、従来のルールベース処理に比べて、AI モデルによる制御が有用であることを示し

ている。本 AI モデルを用いた実験用のハードウェア構成として、AI-OBC を中心とした「AI 教育用衛星システム」に、4 つのフィルムヒータ、4 つの半導体温度計測センサ(Analog Devices 社製 TMP36)、精太陽センサ(SOLAR MEMS Technologies 社製 NanoSSOC-A60)、地磁気姿勢センサ(Bartington Instruments 社製 Spacemag-Lite)を接続し、200 mm 角のアルミニウム衛星構体の温度制御が実施できることを確かめた。




図 12 自律性能評価におけるハードウェア構成図




図 13 従来のルールベース処理によるヒータ制御




図 14 オンボード AI モデルによるヒータ制御

科学衛星にオンボード AI デバイスを搭載してミッションデータを衛星機上で知的処理することを想定し、自律性能評価を行う実習を実施した。例題として科学衛星による電磁界波形観測に着目し、周波数スペクトルを基にリアルタイムで特性周波数(Upper Hybrid Resonance 周波数)を自動検出する仕組みを構築した。UHR (Upper Hybrid Resonance) 放射とは、磁場中でプラズマ振動とサイクロトロン運動する電子が共鳴し、高周波帯域で発生するプラズマ波動であり、その発生周波数は UHR 周波数と呼ばれる。電子密度は、宇宙プラズマにおける波動粒子相互作用を定量的に評価するための重要なパラメータの一つであり、UHR 周波数から推定できる[26, 27, 28]。地球近傍の宇宙空間である「ジオスペース」のプラズマ圏やプラズマトラフ(プラズマ圏外の低密度領域)などの典型的な領域は電子密度によって特徴づけられ、プラズマ圏の境界であるプラズマポーズの位置を知ること、相対論的電子の損失と生成に関連するプラズマ波の分布を理解するために重要である。衛星機上でプラズマポーズの内外をリアルタイムで判定できるようになれば、観測器の動作モードを自動的に切り替えるなど運用の高度化が実現できる。また、衛星機上で宇宙プラズマ中の諸現象を解析して特徴を得ることで、地上に送信するデータ量の削減や取捨選別に貢献できる。

UHR 放射の周波数(UHR 周波数) f_{UHR} は、電子サイクロトロン周波数 f_{ce} および電子プラズマ周波数 f_{p} を用いて、次式で表される。

$$f_{\text{UHR}} = \sqrt{f_{\text{ce}}^2 + f_{\text{p}}^2}$$

f_{ce} は衛星位置での磁場観測により求めることができる。したがって、次式を用いて求めた f_{p} を次式に代入することで、その場の電子密度 n を導出できる。なお、 e は電子の電荷、 m は電子の質量、 ϵ_0 は真空の誘電率を表す。

$$f_{\text{p}} = \frac{1}{2\pi} \sqrt{\frac{ne^2}{m\epsilon_0}}$$

図 15 は 2017 年 11 月 27 日にあらせ衛星で観測された UHR 放射の一例である。図 15 (a) は、観測された電界パワースペクトル密度のスペクトログラムであり、図 15 あらせ衛星で観測された UHR 放射の例(b) は、スペクトログラムに UHR 周波数を重ねてプロットした図である。白線で示された狭帯域の波動が UHR 放射である。図 16 は、これをある時間に着目した周波数スペクトル図で表示した結果であり、真の UHR 周波数と類似した雑音や自然現象が多くみられ、UHR 周波数を同定することが容易でないことが分かる。




図 15 あらせ衛星で観測された UHR 放射の例(f-t ダイアグラム)




図 16 あらせ衛星で観測された UHR 放射の例(周波数スペクトル)




図 17 構築したリアルタイム UHR 周波数推論システム

図 18 に UHR 周波数自動検出モデルの構造を示す。設計した機械学習モデルは、FFT 処理後の 1 次元データを入力としている。具体的には、サンプリング点数を $2x$ 点とした場合、FFT 処理後のデータ点数は x 点となり、モデルの入力データ形式は $(1, x)$ となる。本モデルは 1 次元データを扱うため、全結合層を主構成要素とするシンプルなアーキテクチャを採用する。また、モデルの出力形式は、UHR 周波数を識別するために確率形式の $(1, x)$ とする。




図 18 UHR 周波数のリアルタイム推定に用いたモデルアーキテクチャ

図 19 に UHR 周波数に対するラベルデータと予測データの関係を示す。UHR 周波数自動検出モデルは、FFT 処理後の振幅スペクトルを入力して、予測される UHR 周波数のビン番号を確率形式で出力する。ラベルデータは、UHR 周波数に対応するビン番号を One-hot ベクトル形式で表現している。UHR 周波数の自動検出タスクの場合、出力クラスが 1 つ異なっても、実際の UHR 周波数と予測された周波数との差は FFT 結果に基づく周波数ビンの幅程度の小さな差に過ぎず、予測結果が全く異なるわけではない。このため、UHR 周波数自動検出モデルの精度を一致率で評価するのは不適切であり、誤差率で示すことが望ましい。平均絶対誤差率 (Mean Absolute Percentage Error; MAPE) は、データ数 n 、 i 番目のデータの予測値 $\hat{y}_i$ 、正解値 y_i を用いて、次式で表される。

$$\text{MAPE} = \frac{100}{n} \sum_{k=1}^n \left(\frac{|\hat{y}_i - y_i|}{y_i} \right)$$

UHR 放射を模擬するために、信号発生器で出力する正弦波の周波数を 1 kHz から 20 kHz の範囲で 1 kHz 毎に変化させた。そこに、ホワイトノイズと 5 kHz, 10 kHz, および 15 kHz の各周波数で生成した狭帯域ノイズを、UHR 放射を模擬した信号に重ね合わせた。図 20 はその一例である。これを AI-OBC で推論させたところ、図 20 の紫点に示すように UHR 周波数をほぼ誤差なく推定できることを確認した。UHR 放射は有限の帯域幅を有しており、UHR 周波数は UHR 放射の上端周波数と定義されるため、図 20 の推定結果は極めて良好である。




図 19 誤差の評価方法




図 20 UHR 放射を模擬した信号

UHR 周波数のリアルタイム検出処理を行った際の消費電力を測定した。一般的な超小型衛星に搭載される OBC は数 W 程度の消費電力で動作するように設計されている。このため、本事業でも 3 W をベンチマークとし、消費電力を評価した。図 21 に、FPGA でサンプリング、A/D 変換、SPI 通信によるサンプリングデータの送信を行った際の消費電力の推移と、AI-OBC (DRP) でサンプリングデータの受信、FFT 処理、機械学習モデルによる推論を行った際の消費電力の推移を示す。図 21 において、0 秒から 140 秒までと 470 秒から 510 秒までの AI-OBC と FPGA が推論に係る処理を行っていない時間帯をアイドル状態と定義する。一方、140 秒からリアルタイム推論処理を開始し、470 秒で終了するまでの時間帯をビジー状態と定義する。表 5 には、アイドル状態およびビジー状態における各デバイスの消費電力の平均値と標準偏差を示す。図 21 から、FPGA でサンプリング、A/D 変換、SPI 通信によるサンプリングデータの送信を行う際の消費電力は時間経過に伴う変動がほとんど見られなかった。一方で、AI-OBC でサンプリングデータの受信、FFT 処理、機械学習モデルによる推論を行う際の消費電力の変動幅が大きいことが確認できた。表 5 から、AI-OBC と FPGA のビジー状態における平均消費電力の合計は 2.74 W であり、設定したベンチマークである 3 W を十分に下回っていることが確認できた。各デバイスのアイドル時とビジー時の消費電力の差を比較すると、AI-OBC は +0.15 W、FPGA は +0.004 W であった。この差は、サンプリングと推論による消費電力の増加分を示しており、両者の合計は約 +0.16 W であった。これはデバイス自身が消費する電力(数 W)に対して十分小さな量であり、衛星機上での処理に支障ないことが示された。全結合層主体のモデルでは、畳み込み層を多く用いるモデルと比べて計算負荷が軽減され、消費電力の増加を抑制できたと考えられる。




図 21 UHR 周波数のリアルタイム推定中の消費電力推移

表 5 UHR 周波数のリアルタイム推定における平均消費電力

デバイス	アイドル状態		ビジー状態	
	平均値 (W)	標準偏差 (W)	平均値 (W)	標準偏差 (W)
DRP	1.17	0.0176	1.33	0.0922
FPGA	1.405	0.0012	1.409	0.0019

図 22 および図 23 は、自律性能評価実習の受講者 7 名に対して、実施後にアンケートの回答を求めた結果である。全ての受講者が、本実習を通して宇宙・AI・データサイエンスに関する理解度が「とても向上した(最高評価)」と回答しており、本実習プログラムの内容が適切に構成され効果を発揮したことを裏付けている(Q1)。進学先や就職先の検討に本実習の経験がどの程度影響したか(Q2)について、7 名中 4 名が「とても影響した(最高評価)」と回答し、他 2 名が「やや影響した(上位から 2 番目)」と回答した。また、本実習で得た知識や経験が、進学や就職活動に役立ったか(Q3)について、7 名中 5 名が「とても役に立った(最高評価)」と回答した。これらのことから、本実習が学生に提供した機会が個々人の進路決定に大きく影響をもたらしたことが示され、宇宙技術分野や AI 応用の分野に知見を有した学生を輩出することに貢献できたと考えられる。本実習が、具体的にどのように進学や就職活動に役立ったかを調査したところ、


- どの会社でも AI といった DX 化を推進しており、AI を搭載した組み込みシステムの研究をしていることを話すと興味を持ってもらえた。
- 就職面接時にエッジ AI のことに対して大変興味を持っていただけた。また、宇宙関係のお話もすることができた。
- 衛星開発を通して得た経験(チーム開発経験や組み込みソフトの開発経験等)を述べることもできた。また、就職面接や座談会等で衛星開発をしていると伝えると興味を示してくれた。宇宙系ではない企業の場合、先方から問われた内容は宇宙に直接かかわる内容ではなく、チーム開発に関する内容が多かった(チームの規模間や、チーム内での自分の立ち位置、学んだこと等)。
- 自動車業界を軸に就職活動を進めていたが、自動車業界でも現在、AI や宇宙で求められる組み込みシステムの技術が必要とされており、私の研究に強い関心を示してもらえた。

等の回答を得た。以上の内容から、本実習で得た知識や経験が宇宙技術分野への進学・就職に効果的であっただけでなく、そのほかの業種においても実習・開発経験を通したもののづくりの考え方や共同作業への参画方法などの点で波及的効果をもたらしたことが分かる。本実習で扱ったテーマの社会的重要性(Q4)について、7 名中 6 名の参加者が「とても重要だと思う(最高評価)」と回答しており、本事業がフォーカスする課題の重要性を参加者自身が着実に理解できたことが示された。最後に、本実習の経験を踏まえて博士後期課程に進学してさらに研究してみたいか(Q5)を問うと、「博士後期課程への進学を真剣に考えた」と回答したのは 7 名中 1 名であり、他 3 名の学生が「博士後期課程への進学を少しは考えた」と回答したにとどまった。宇宙・AI 分野への就職活動には本取り組みが効果的であったことが示された一方、博士後期課程への誘いにはやや課題点が残されていることを示している。これには、分野に依らず博士後期課程の進学率が伸び悩むことに対して、進学を後押しする社会的制度の拡充が必要であるとの声があり、学術分野全体として取り組んでいくべき課題であると考えられる。7 名のうち 1 名(博士前期課程学生)は、本実習プログラムへの参加を通して宇宙航空分野の国内研究機関への就職を志願し、翌年度に入社することが決定している。このことから、本事業が若手人材の発掘と将来の進路に関する意思決定に大きく寄与したことが示された。

Q. 1 衛星搭載ハードウェア・オンボードソフトウェア・オンボードAIの開発を通じて、「宇宙・AI・データサイエンス（いずれか）」に関する理解度はどの程度向上しましたか



Q. 2 衛星搭載ハードウェア・オンボードソフトウェア・オンボードAIの開発を通じて得た「宇宙・AI・データサイエンス（いずれか）」に関する知識・経験は、進学先や就職先（あるいは就職先で希望する職種の希望）の選択・検討にどれくらい影響しましたか（最終結果ではなく、進路を考える過程にどれくらい影響したかを教えてください）



Q. 3 衛星搭載ハードウェア・オンボードソフトウェア・オンボードAIの開発を通じて得た「宇宙・AI・データサイエンス（いずれか）」に関する知識・経験は、進学や就職活動に役立ちましたか





図 22 自律性能評価実習の受講後アンケート結果（1/2）

Q. 4 衛星搭載ハードウェア・オンボードソフトウェア・オンボードAIの開発を通じて得た「宇宙・AI・データサイエンス（いずれか）」に関する知識・経験は、今後の社会にとってどの程度重要だと感じますか



Q. 5 衛星搭載ハードウェア・オンボードソフトウェア・オンボードAIの開発を踏まえ、博士後期課程に進学してさらに研究をしてみたいと感じたことはありましたか



図 23 自律性能評価実習の受講後アンケート結果 (2/2)

2.2 自発的な研究活動等

自発的な研究活動等に関する実施方針に基づき、所属機関が認めた範囲で自発的な研究活動等を推進した。

3 まとめ

本年度の委託業務として、AI 教育用衛星システムを用いたオンボード AI の実装と評価を行うことを目標とし、「オンボード AI モデルの搭載実習」と「自律性能評価実習」に取り組んだ。

「オンボード AI モデルの搭載実習」では、前年度までの委託業務で開発した超小型衛星向けオンボード AI デバイスである「AI-OBC」を用い、大学生・大学院生が独自の畳み込みニューラルネットワークや、ResNet, YOLO といった既存のモデルアーキテクチャを組み込むことによる推論精度、推論速度、消費電力等の確認を行った。AI-OBC の単体性能評価に加え、組み込みシステム向け SoC や一般的な CPU・GPU との処理性能比較を行い、AI-OBC が極めて高い電力効率で高速な AI 推論を実現できることを示した。また、高校生・高専生向けの AI モデル搭載実習として、地球観測データを用いた土地利用土地被覆図の再現を行うタスクに取り組み、これをエッジデバイス上で動作させることで、エッジ環境における推論性能の向上に向けた改良や、環境由来の制約の理解を深めた。参加者らが構築した AI モデルは AI-OBC でも動作させることを示し、参加者らに宇宙における AI 利用の方法を学ぶ機会を提供した。これらの取り組みの前後にアンケート調査を実施し、実習を通して宇宙での AI 応用に関する知識を効果的に身に付けさせたこととともに、取り組みを通して将来の進路決定への働きかけの効果を明らかにした。また、本プログラムを通して実際に宇宙航空業界への就職を志願し、進路を決定した参加者もあり、本事業が若手人材の発掘に寄与したことを示した。

「自律性能評価実習」では、軌道上における温度環境変化に対して自律的にヒータ制御を行う熱制御系システムの開発をテーマとして挙げ、オンボード AI モデルによる衛星システム制御の一例として金沢大学の大学生・大学院生が実習に取り組んだ。また、科学衛星にオンボード AI デバイスを搭載してミッションデータを衛星機上で知的処理することを想定し、自律性能評価を行う実習を実施した。特に、科学衛星による電磁界波形観測に着目し、周波数スペクトルを基にリアルタイムで特性周波数(Upper Hybrid Resonance 周波数)を自動検出する仕組みを構築した。これらの性能評価を通して、衛星搭載可能なエッジデバイスを用いた衛星システム・ミッション機器制御のフィージビリティを確認し、オンボード AI を搭載した科学衛星の実現に目途をつけた。また、実習参加者から収集したアンケート調査によって、教育的効果の程度を定量的に評価したとともに、本実習が学生に提供した機会が個々人の進路決定に大きく働きかけたことを確認した。

令和 4 年度から 3 か年計画で実施した本事業を通して、約 400 名の中学生・高校生・高専生・大学生・大学院生を「AI×宇宙技術教育プログラム AI-STEP」の一般参加者として集めた。「AI-STEP 特別講義」「AI-STEP ワークショップ」「AI-STEP コンペティション」を通して、宇宙ビッグデータに対する AI 応用と、宇宙機搭載デバイスによる知的処理に特化して学ぶ機会を提供した。「AI-STEP 特別講義」では、宇宙ビッグデータと人工知能技術に関するオンデマンド教材を開発した。これらのオンデマンド教材は、本事業で開発された学習ポータルサイト「AI-STEP Portal」の登録者が利用できるようにポータルサイト上で公開したほか、情報処理学会(IPSJ)の認定教材として日本オープンオンライン教育推進協議会(JMOOC)が運営するオンライン大学講座でも公開され、広く宇宙分野への AI 応用に興味を持つ人々が利用できるよう整備されている。「AI-STEP ワークショップ」は石川・福井・香川で延べ 6 回開催した。「AI-STEP コンペティション」は計 2 回開催し、金沢大学が所有する衛星運用・観測データ等を活用して実施した。本事業の教育成果を通して、将来宇宙で活躍する人工衛星やコンステレーションのインテリジェント化に携わる若手人材の早期育成を行ったことで、コンステレーションの運用負荷増大や宇宙機の安全管理、膨大なデータの効率的解析方法や有効活用の検討が加速されることが期待される。

これと並行して、将来の超小型衛星のインテリジェント化を実現するためのオンボード AI デバイスとして「AI-OBC」を開発し、その性能を「オンボード AI モデルの搭載実習」と「自律性能評価実習」を通して確かめた。本委託業務で開発した「AI-OBC」を搭載する科学衛星ミッションとして、2023 年 5 月に「IMPACT プロジェクト」を立ち上げ、JAXA-SMASH(産学官による輸送・超小型衛星ミッション拡充プログラム)第 2 回衛星ミッション公募に 2023 年 11 月に採択された。その後 2025 年 2 月に衛星開発フェーズへのフェーズアップが認められ、2027 年の衛星打ち上げを目指して現在開発を進めている(図 24 および図 25)。本衛星ミッションでは「AI-OBC」を衛星のメインコンピュータとし、従来のルールベース処理に基づく衛星システムの制御に加えて、科学データの知的分類や自動識別を行うことで、限定的な通信リソース下でも科学成果を最大化する実験を行うほか、衛星システムの機能として AI モデルによる判断を取り入れる仕組みを構築し、地上からのコマンドによる指示に依らない宇宙機の自律制御を行う計画である。本ミッションの科学目標は、宇宙天気計測を超小型衛星で高精度に実現することで、複数の超小型衛星を活用した将来の三次元宇宙天気計測網の具現化に貢献することと、磁気圏のプラズマ波動が長距離を伝搬して地表に到達する仕組みを明らかにし、伝搬経路を活用した宇宙プラズマの能動的制御を実現するための科学課題を解決することである。本ミッションに AI-OBC を搭載することは、単に AI-OBC の Technology Readiness Level を向上させるだけでなく、科学コンステレーションの運用自律化による運用コストの削減に向けた技術実証を行う意義がある。また、本ミッションを通して AI-OBC の宇宙における実用性を示し、科学目的に限らない地球観測衛星等への搭載や、小型クラス以上の衛星に搭載するサブコンポーネントのプロセッサとしてオンボードインテリジェンスを実現するための応用、また将来の月探査・月居住区の開発に向けた月面観測拠点・自動運転車(ローバー)のプロセッサとしての利用も期待される。



図 24 IMPACT の飛翔想像図




図 25 IMPACT 搭載機器の概要

4 添付資料

なし

学会等発表実績

委託業務題目「高大連携宇宙 AI コンペティションを通した「インテリジェント宇宙機」開発人材の育成」

機関名 国立大学法人金沢大学

1. 学会等における口頭・ポスター発表

発表した成果（発表題目，口頭・ポスター発表の別）	発表者氏名	発表した場所（学会等名）	発表した時期	国内・外の別
Study on Onboard High-Speed Machine Learning Inference using Dynamically Reconfigurable Processor	T. Ukita, S. Matsuda, Y. Kasahara, Y. Morikoshi	Japan Geoscience Union Meeting 2024	2024 年 5 月	国内
Development and Initial Operation of Onboard Data Recorder on the Kanazawa University Satellite “KOYOH”	D. Eguchi, S. Matsuda, Y. Kasahara, T. Imachi, T. Sawano, Y. Shoji, I. Jikuya, M. Arimoto, M. Kimura, D. Yonetoku, S. Yagitani	Japan Geoscience Union Meeting 2024	2024 年 5 月	国内