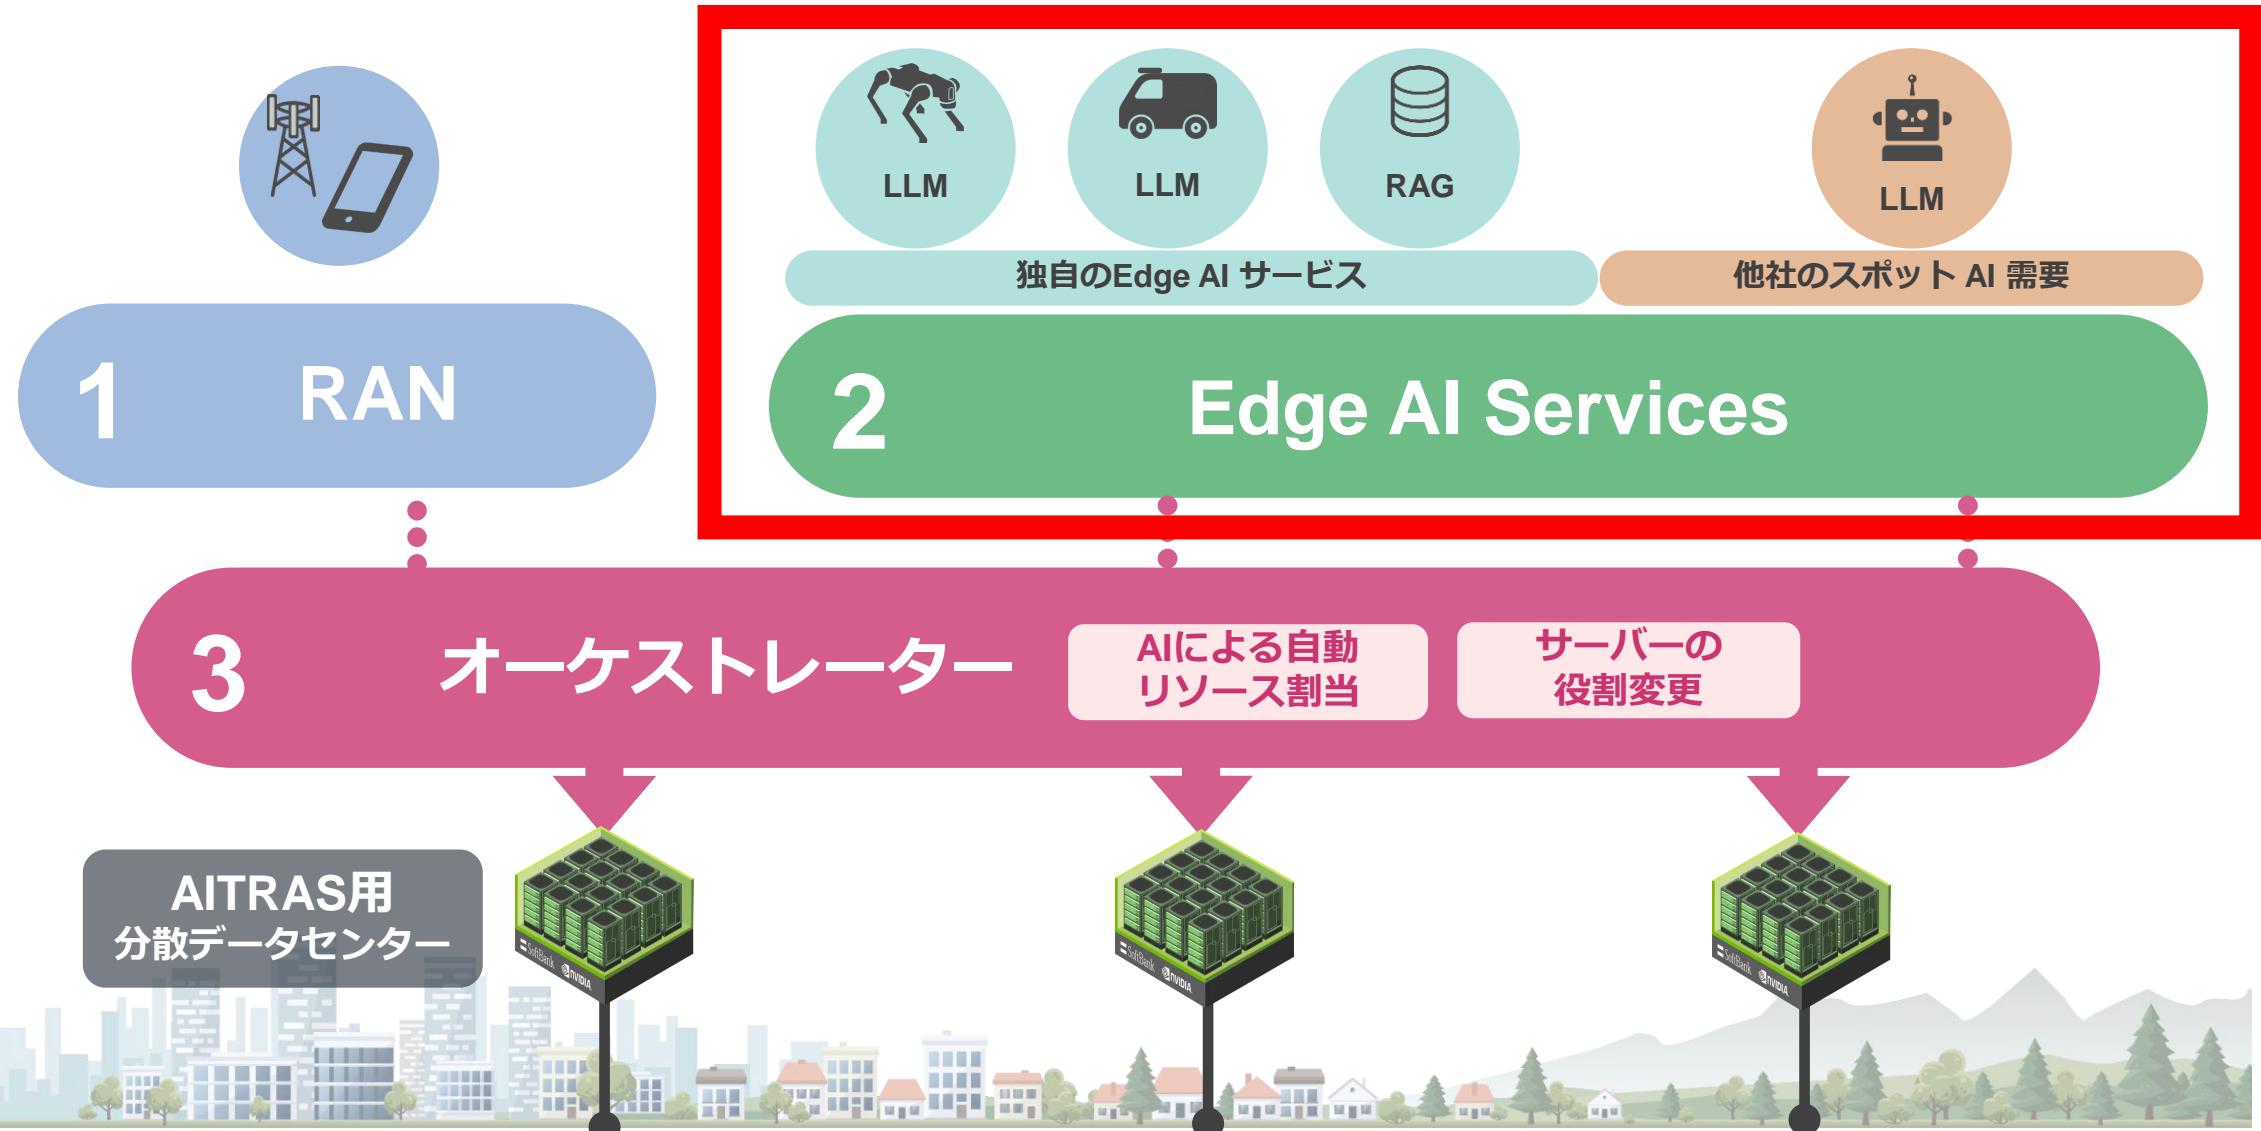
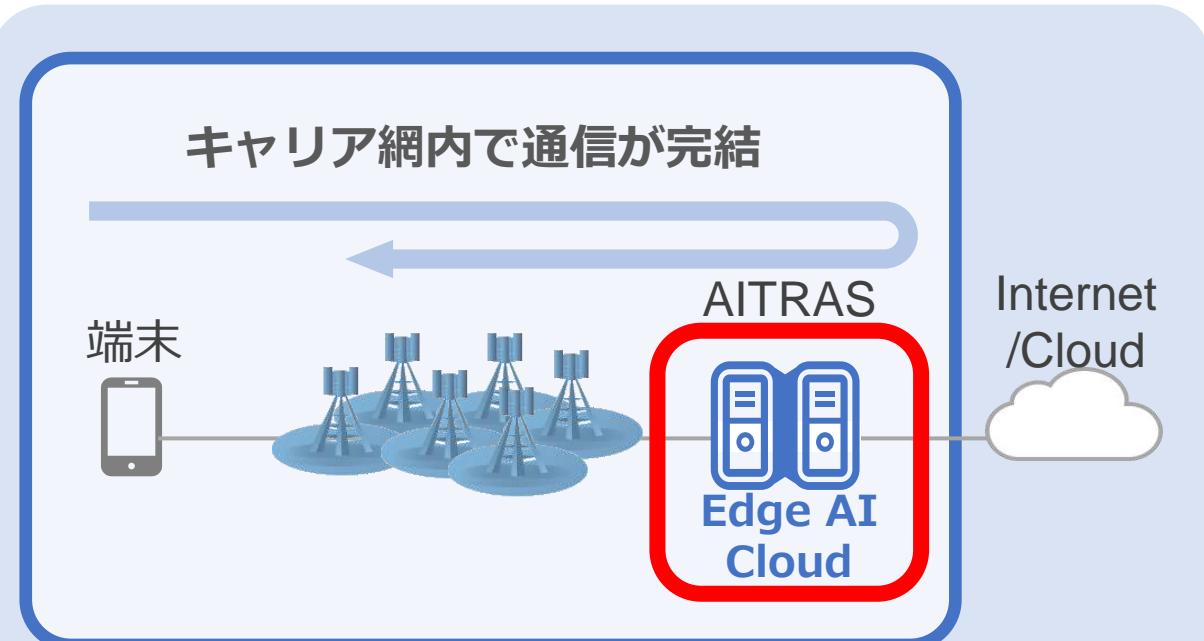


# AITRASの要素技術



# AITRAS の Edge AI の特徴

## ～革新的なAIサービス実現をサポート～

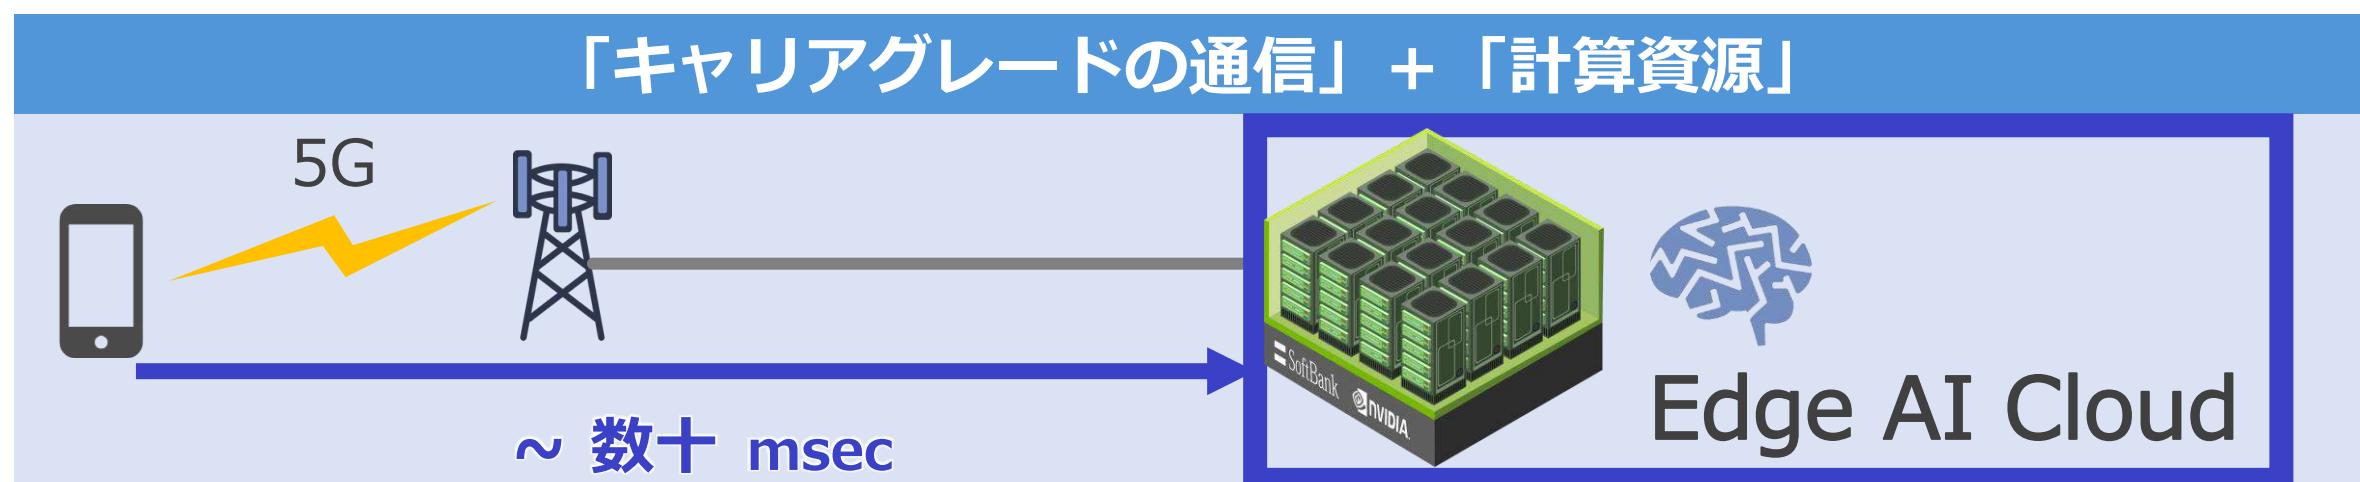


低遅延 & 高セキュリティな  
Edge AI Cloudを提供



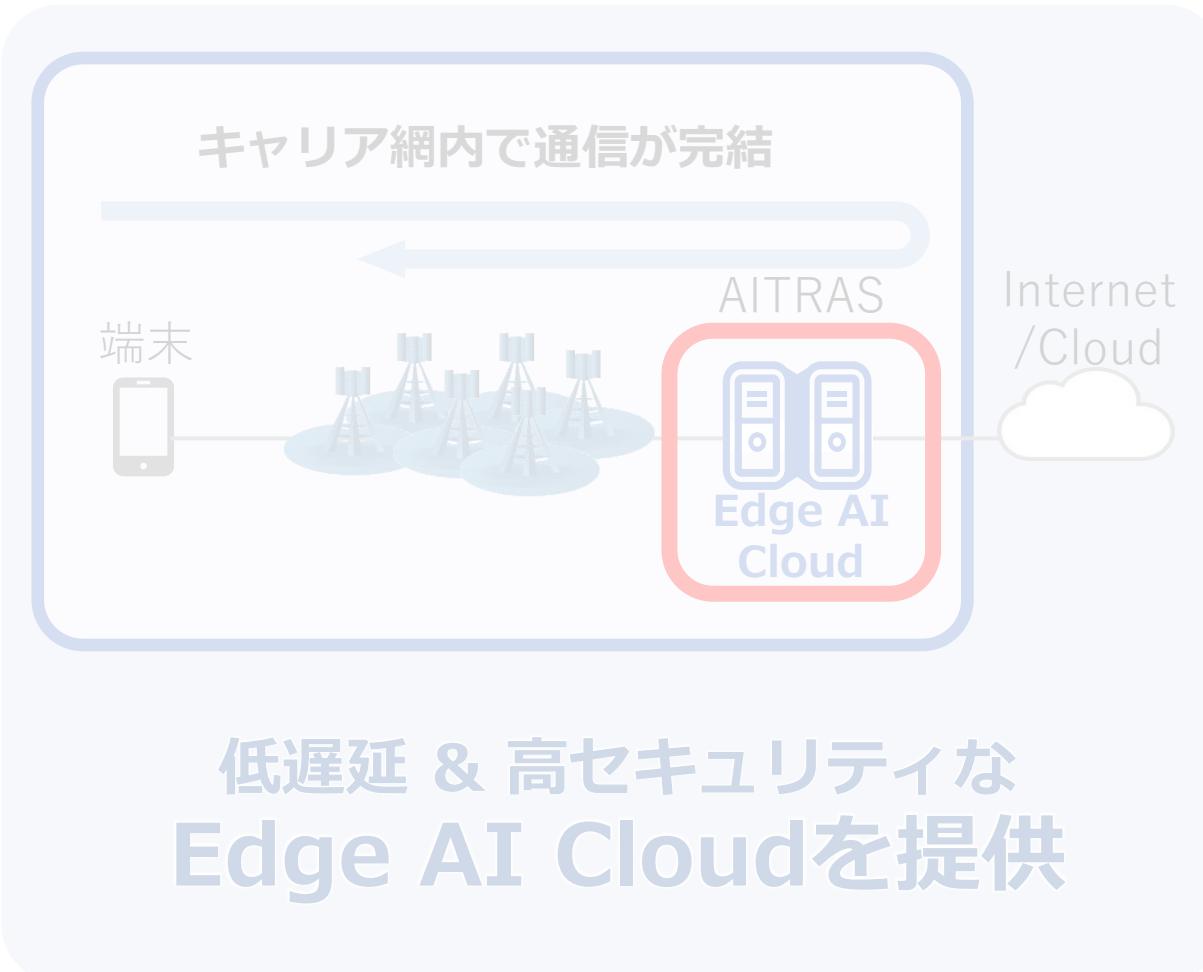
NVIDIA AI Enterpriseと連携した  
スピーディな開発の実現

# キャリアだからこそできる 低遅延＆高セキュリティな Edge AI Cloud



# AITRAS の Edge AI の特徴

## ～革新的なAIサービス実現をサポート～



# NVIDIA AI Enterprise と連携した スピーディな開発の実現

ビジネスロジック、企業データ



NVIDIA AI Enterprise



NIMS\* Microservice

CUDA-x Microservice

AI Application Framework

End-to-End AI Development Tools

Infrastructure Management and Optimization

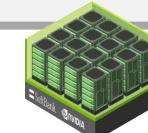
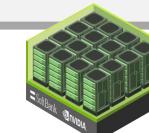
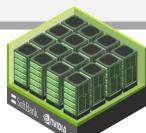
AITRAS上でスピーディな  
AIサービス開発が可能に



NVIDIA AI Enterpriseと連携  
AI開発を強力に支援する機能群



Edge AI Cloud



低遅延&高セキュリティ  
Edge AI Cloud

# AITRASのエッジAIユースケース

## 後ほどデモにて詳細をご説明

AITRAS

オーケストレーター

エッジAI  
NVIDIA AI Enterprise

RAN L2/L3 ソフトウェア

RAN L1 ソフトウェア  
NVIDIA AI Aerial

仮想化基盤

MIG/MPS

NVIDIA GN200  
Arm Neoverse V2

Radio Unit



### SoftBankオリジナル AI サービス

- ◆ 自動運転遠隔サポート
- ◆ Cloud LLMロボ
- ◆ RAG Menu@Edge

### 3rd Party向け Edge AI Cloud

- ◆ Serverless API Powered  
by NVIDIA AI Enterprise  
@Edge

AI Models

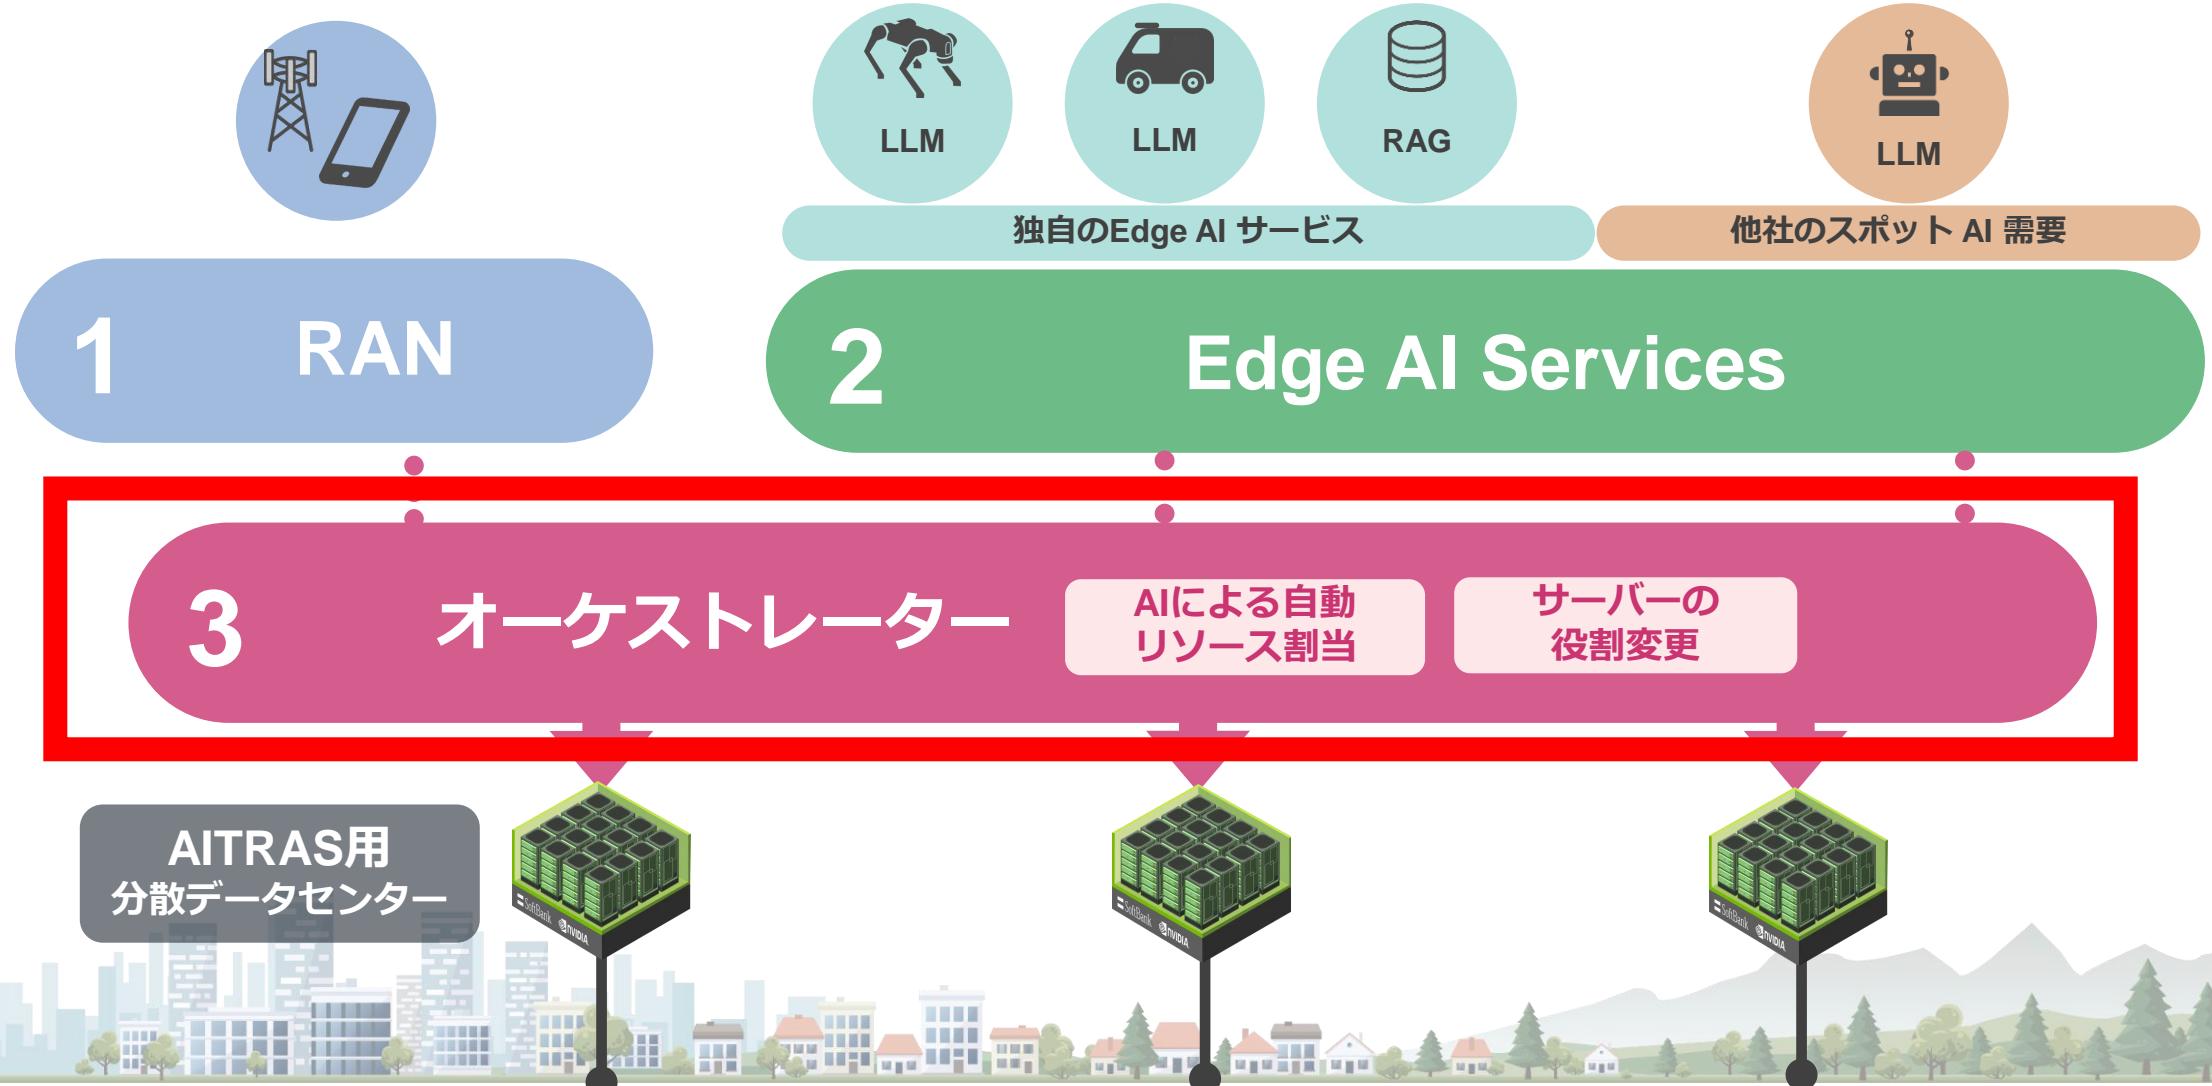
OSS LLM

Partner LLM

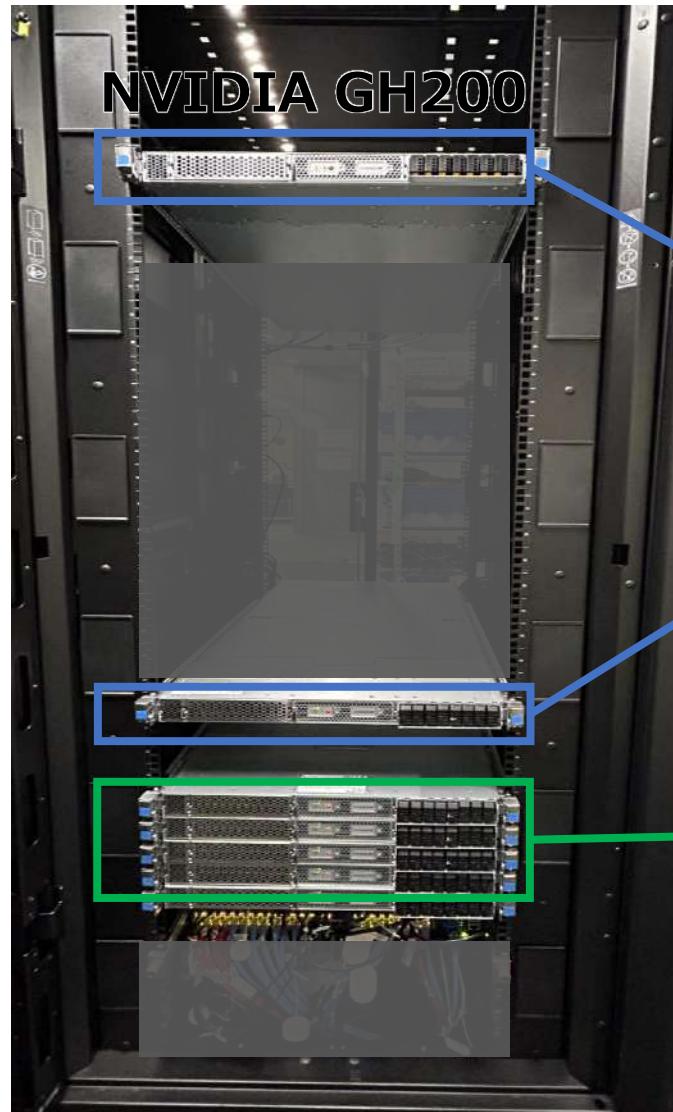
ooo

NVIDIA AI Enterprise

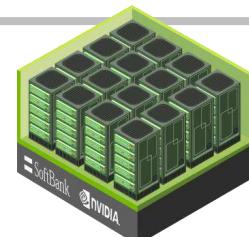
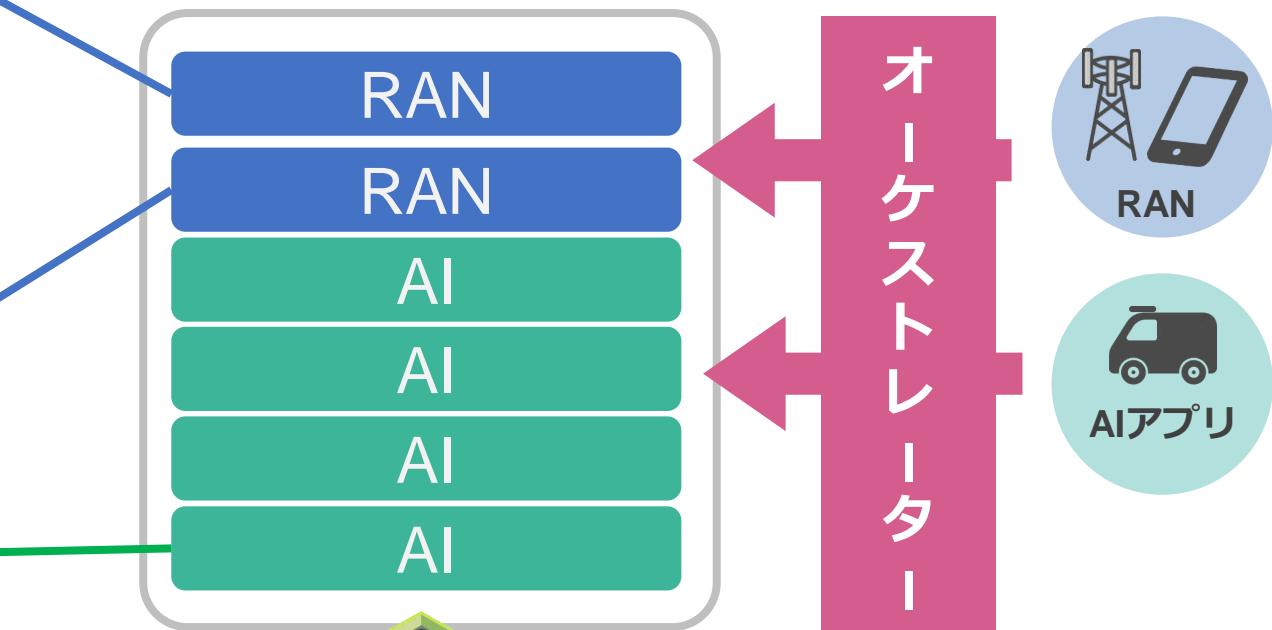
# AITRASの要素技術



# AITRAS オーケストレーター基礎的な機能

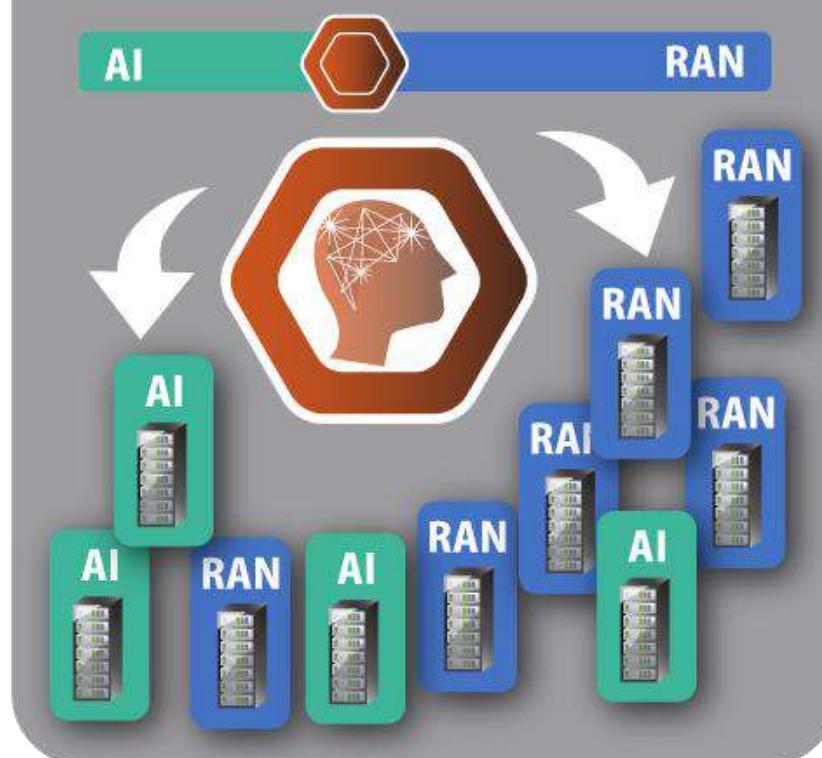


- ✓ サーバーごとに“RAN”か“AI”的役割を切替
- ✓ 役割に応じたアプリをデプロイ

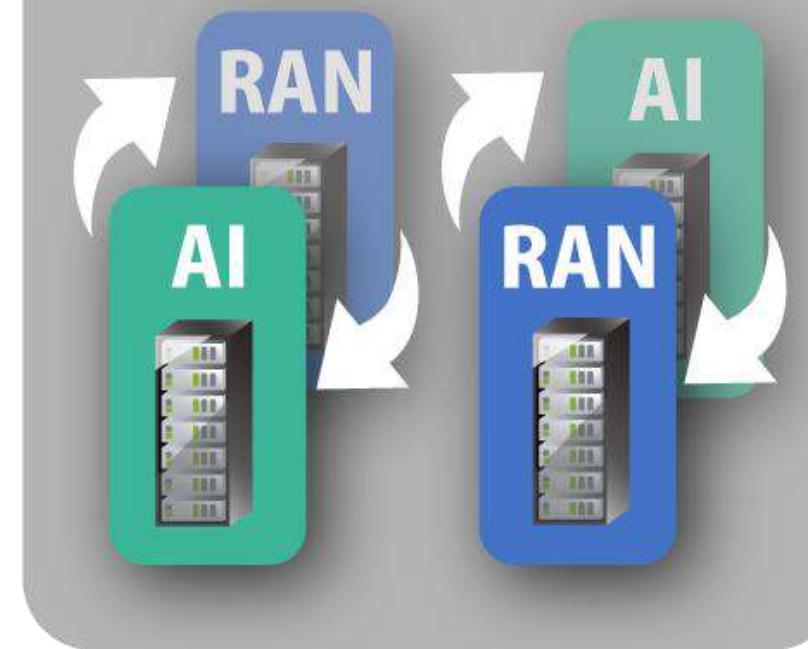


# AITRAS オーケストレーターの大 事な2つの機能

AIとRANの需要を  
最適なリソースに  
割り当て

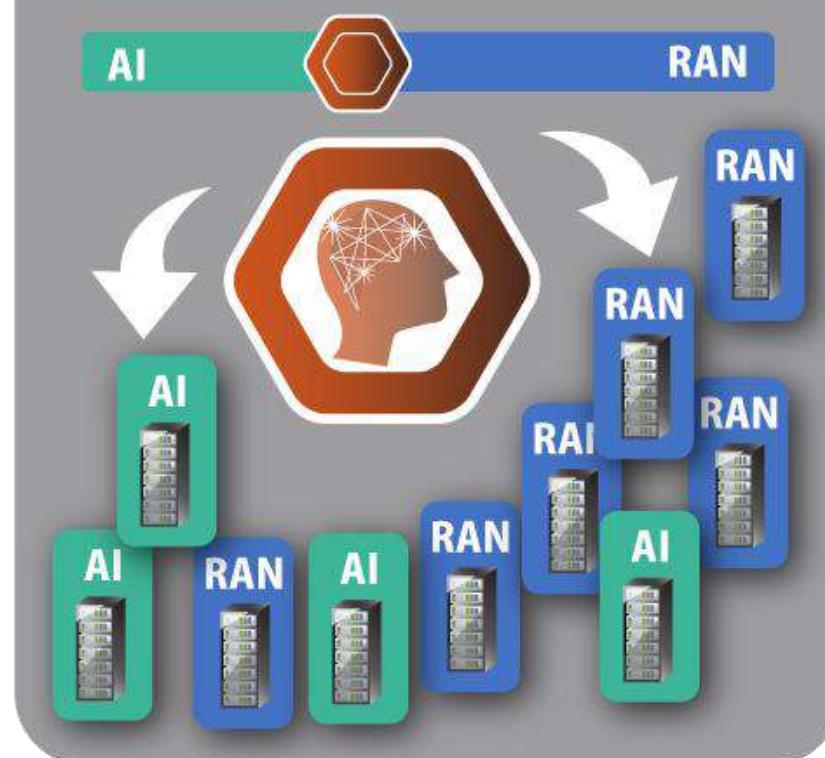


サーバーの役割の  
動的な変更

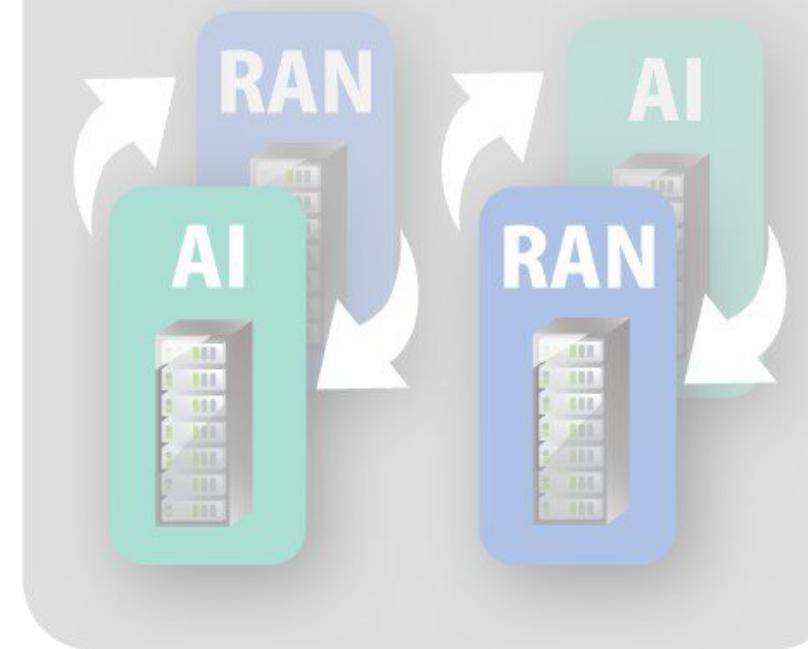


# AITRAS オーケストレーターの大 事な2つの機能

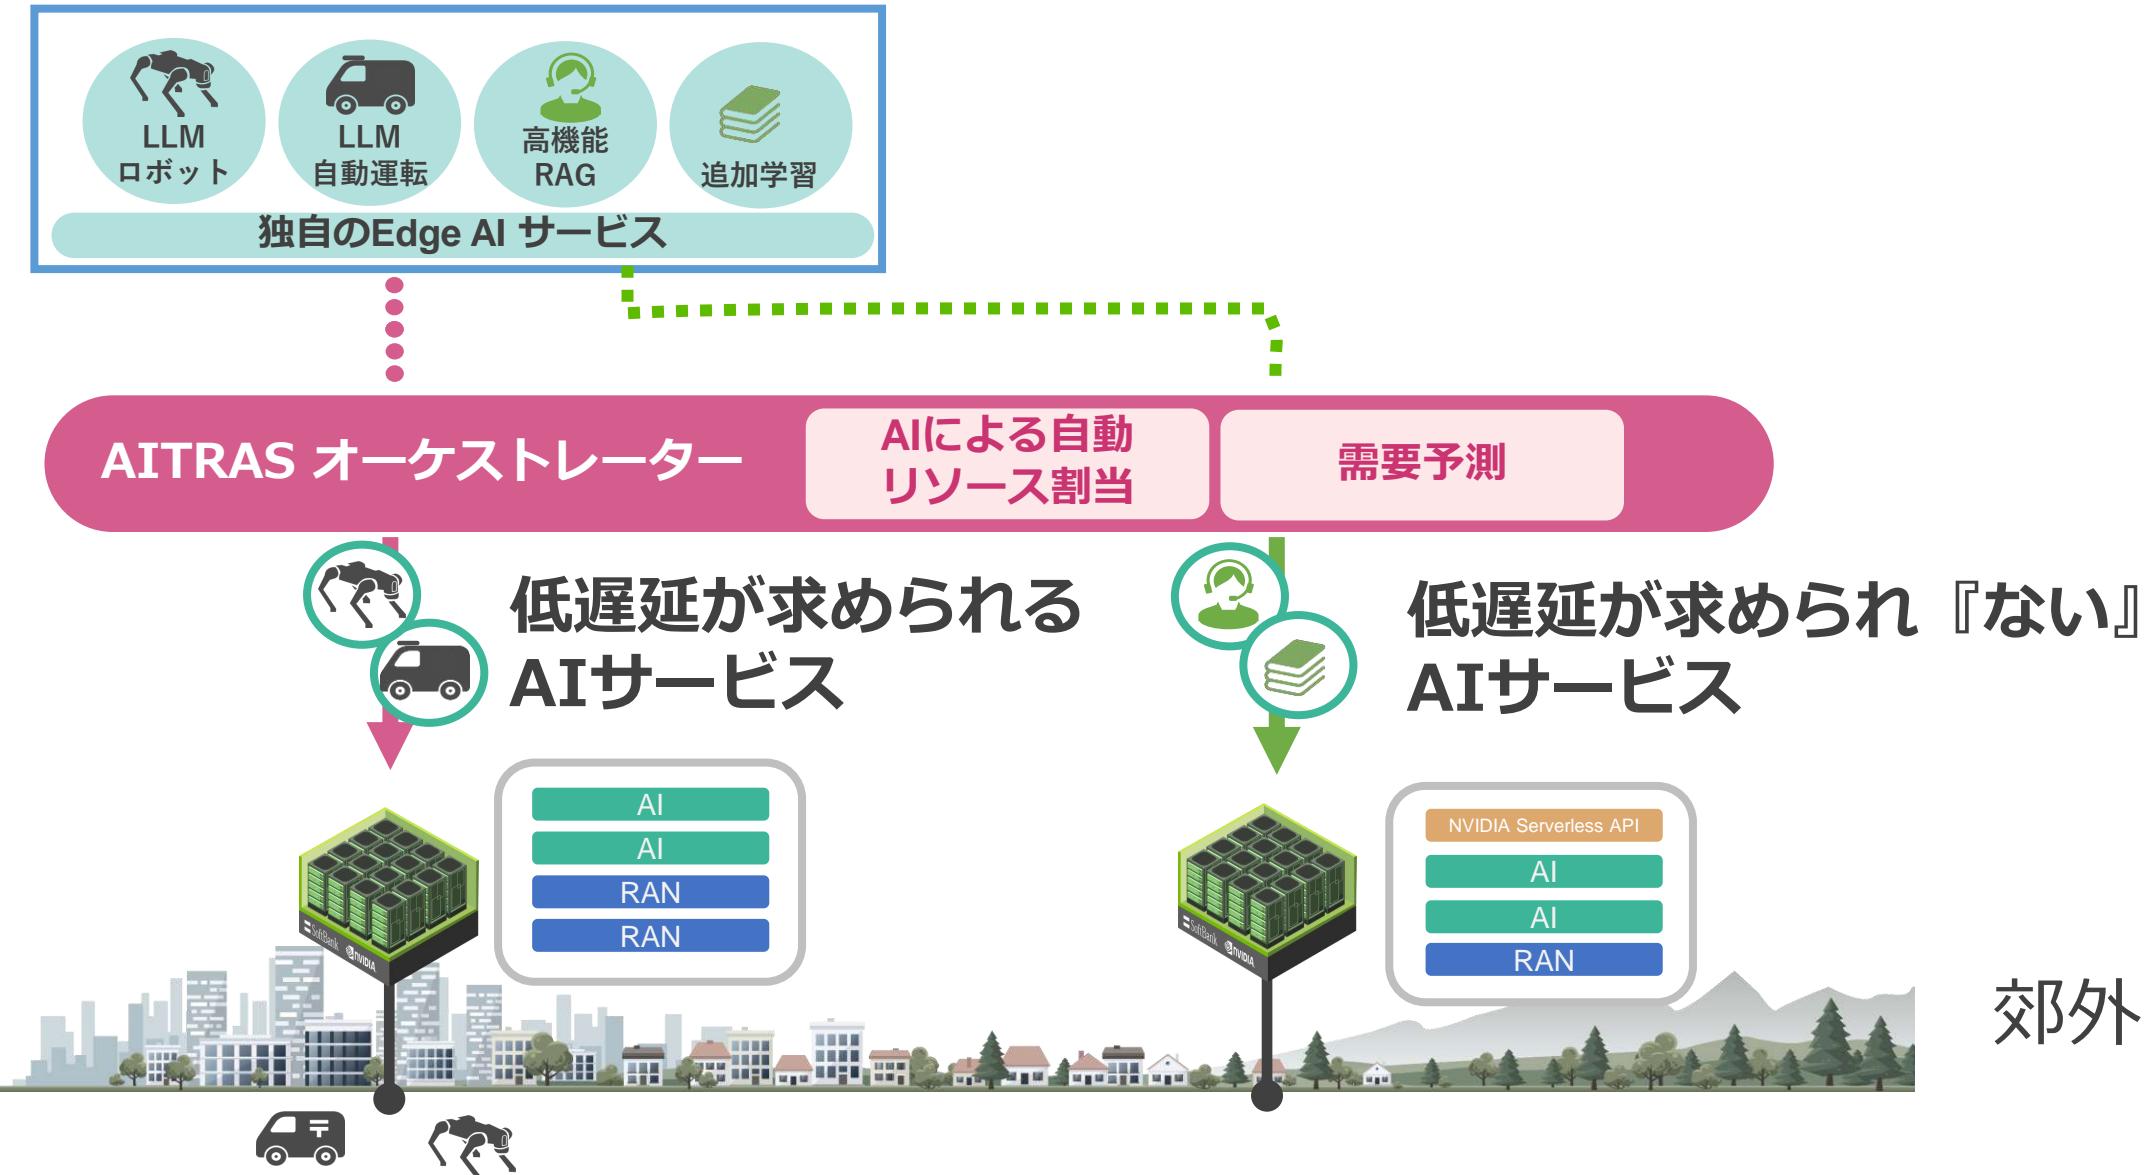
AIとRANの需要を  
最適なリソースに  
割り当て



サーバーの役割の  
動的な変更

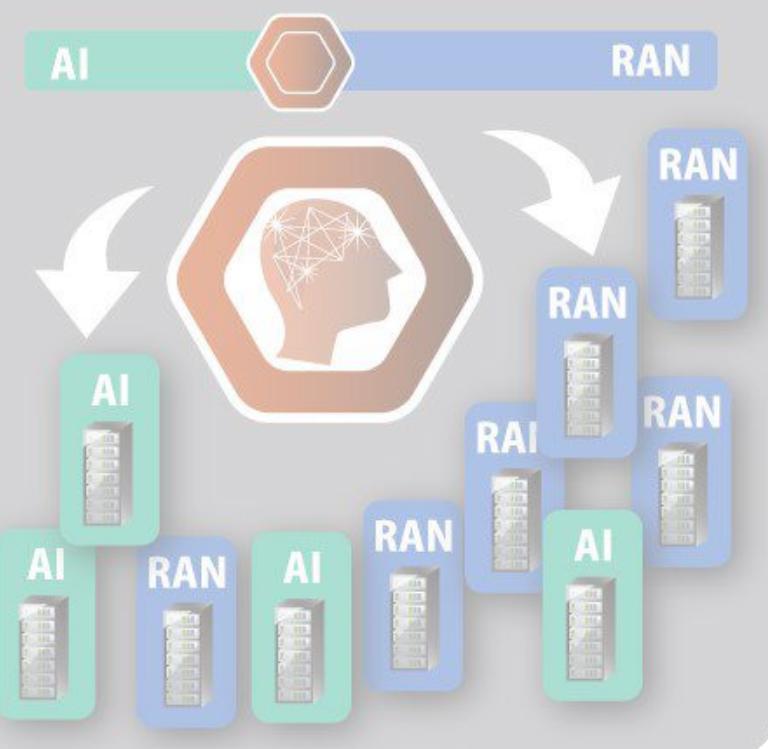


# 用途に応じてサービスを振り分け



# AITRAS オーケストレーターの 大事な2つの機能

AIとRANの需要を  
最適なリソースに  
割り当て

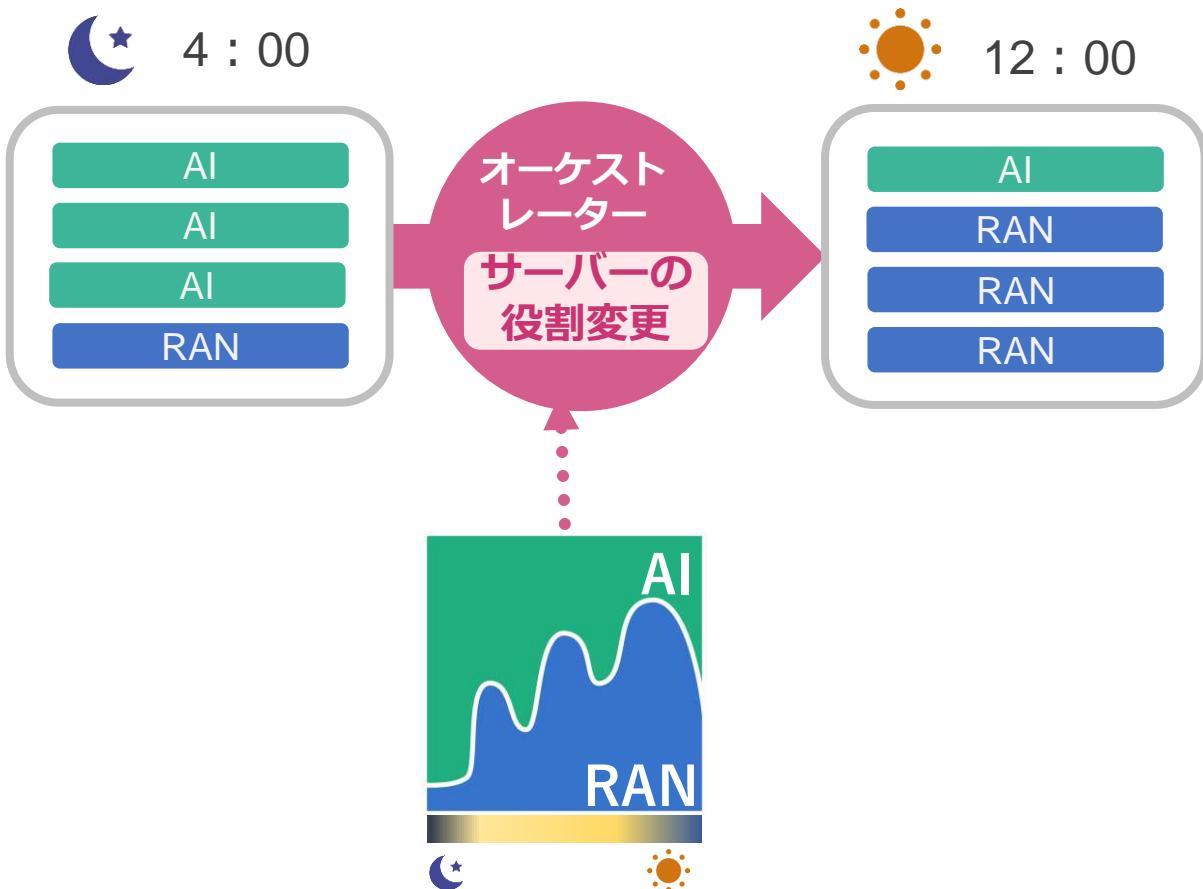


サーバーの役割の  
動的な変更

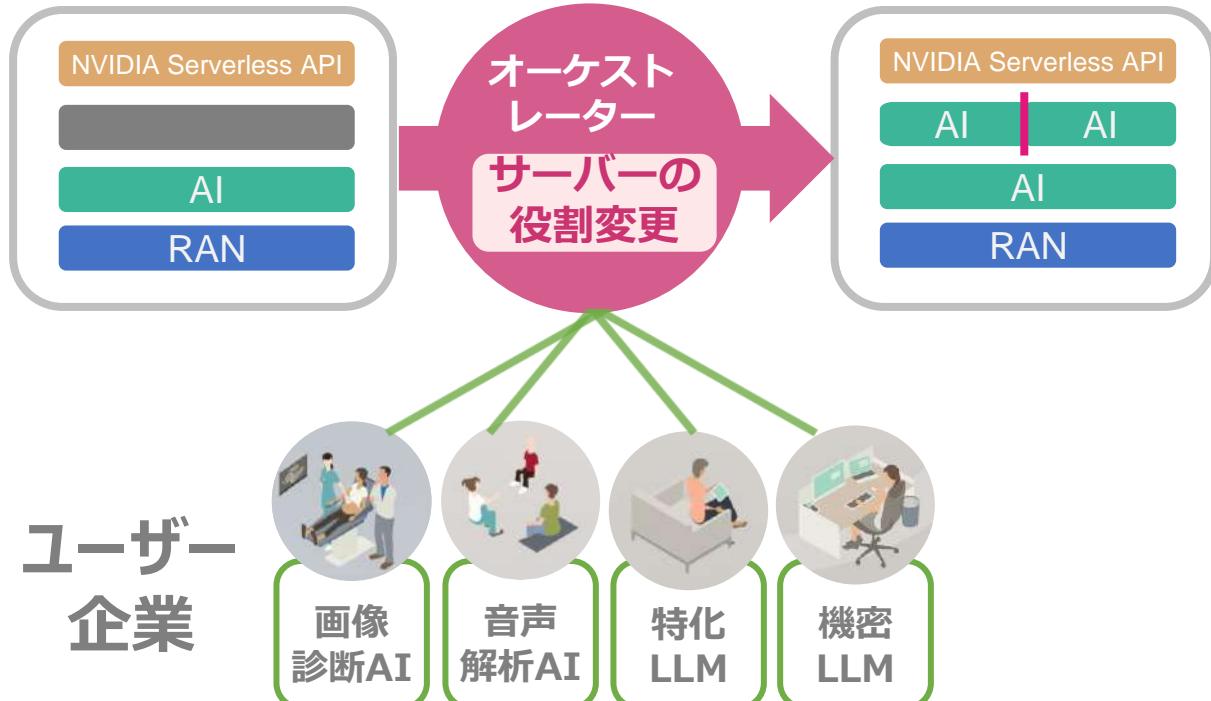


# サーバの役割を最適に変える

## RANの需要に合わせサーバーの役割変更 (AI↔RAN)



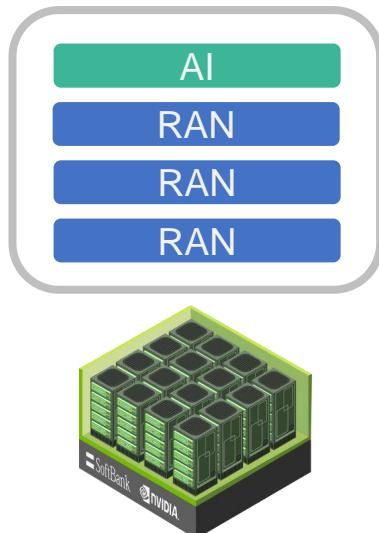
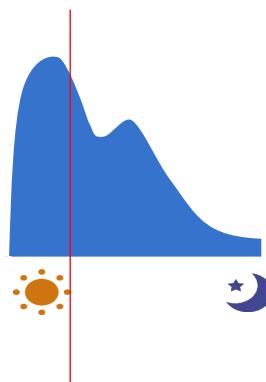
## 需要に応じてGPUを分割 (MIG)



デモ

# デモシナリオ

昼はRANが忙しい

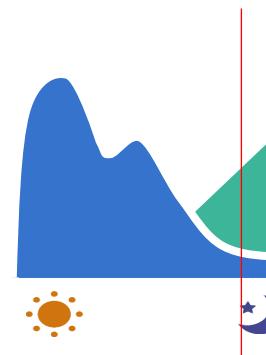


サーバーの  
役割変更

AIによる自動  
リソース割当



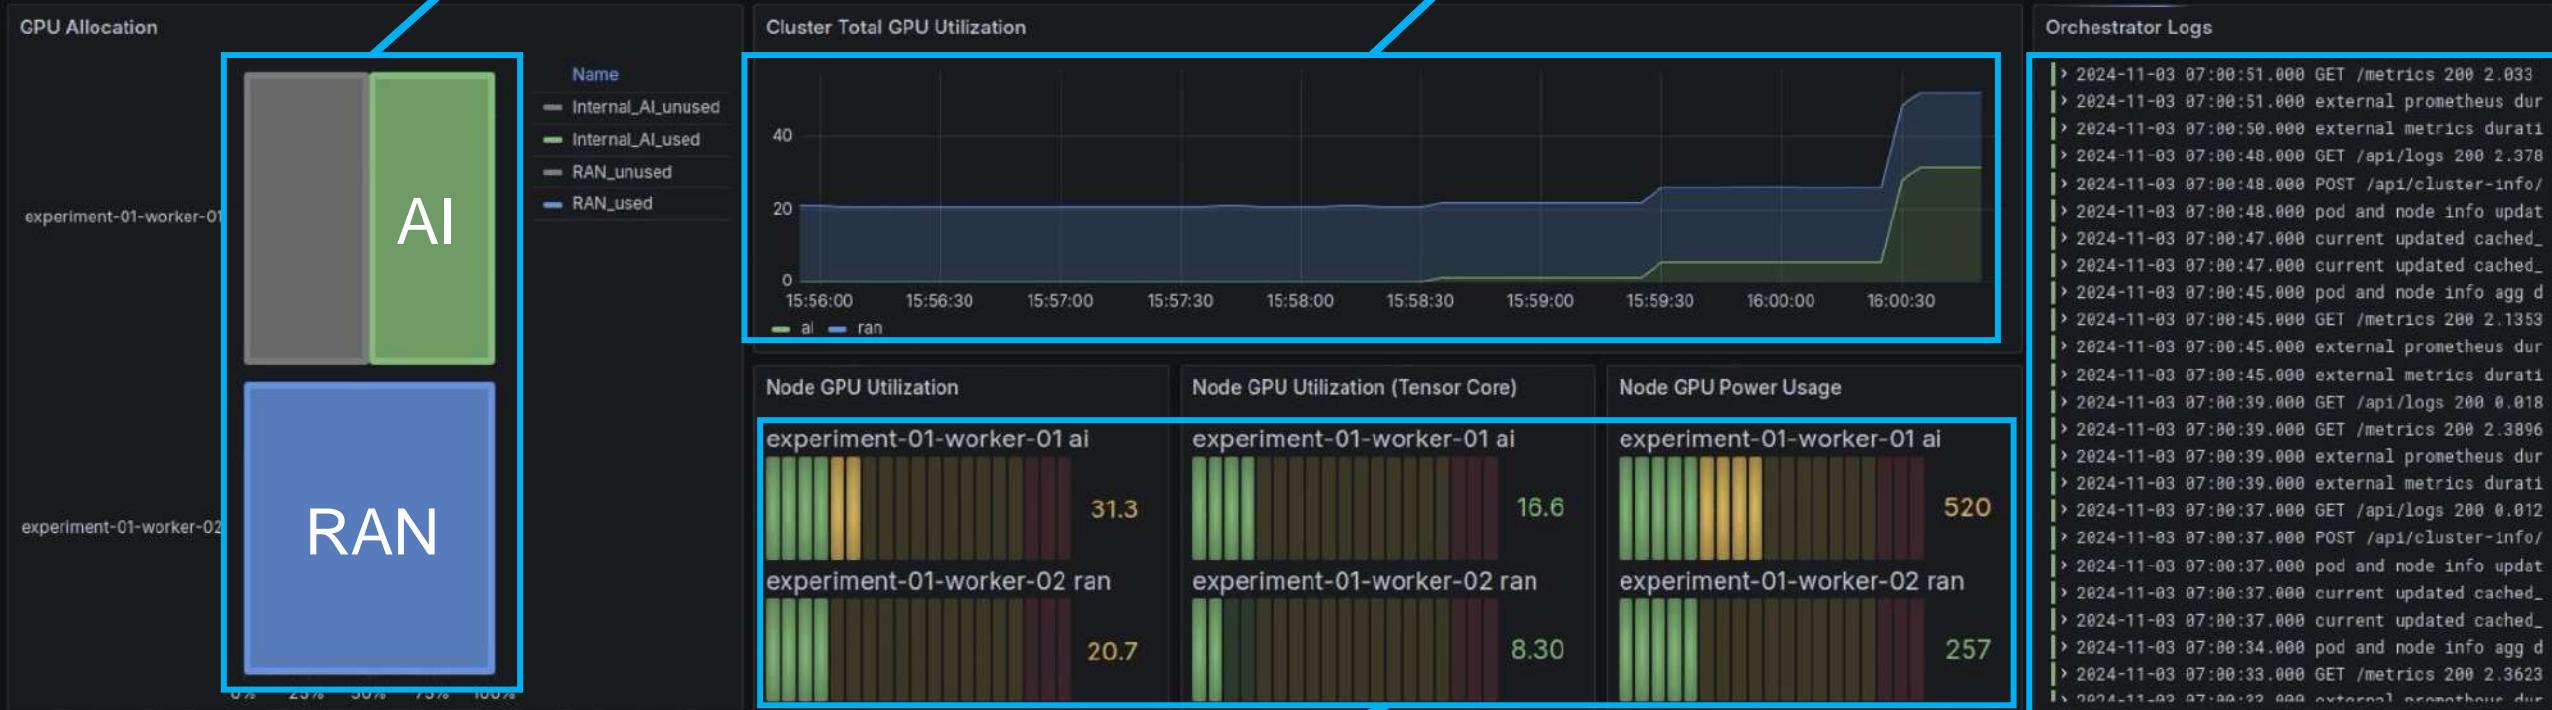
深夜帯になりRANの需給の減少  
サーバーを適切な役割に変更しAIアプリ実行



適切な大きさの  
GPUを  
AIに割り当て  
&AIアプリ実行

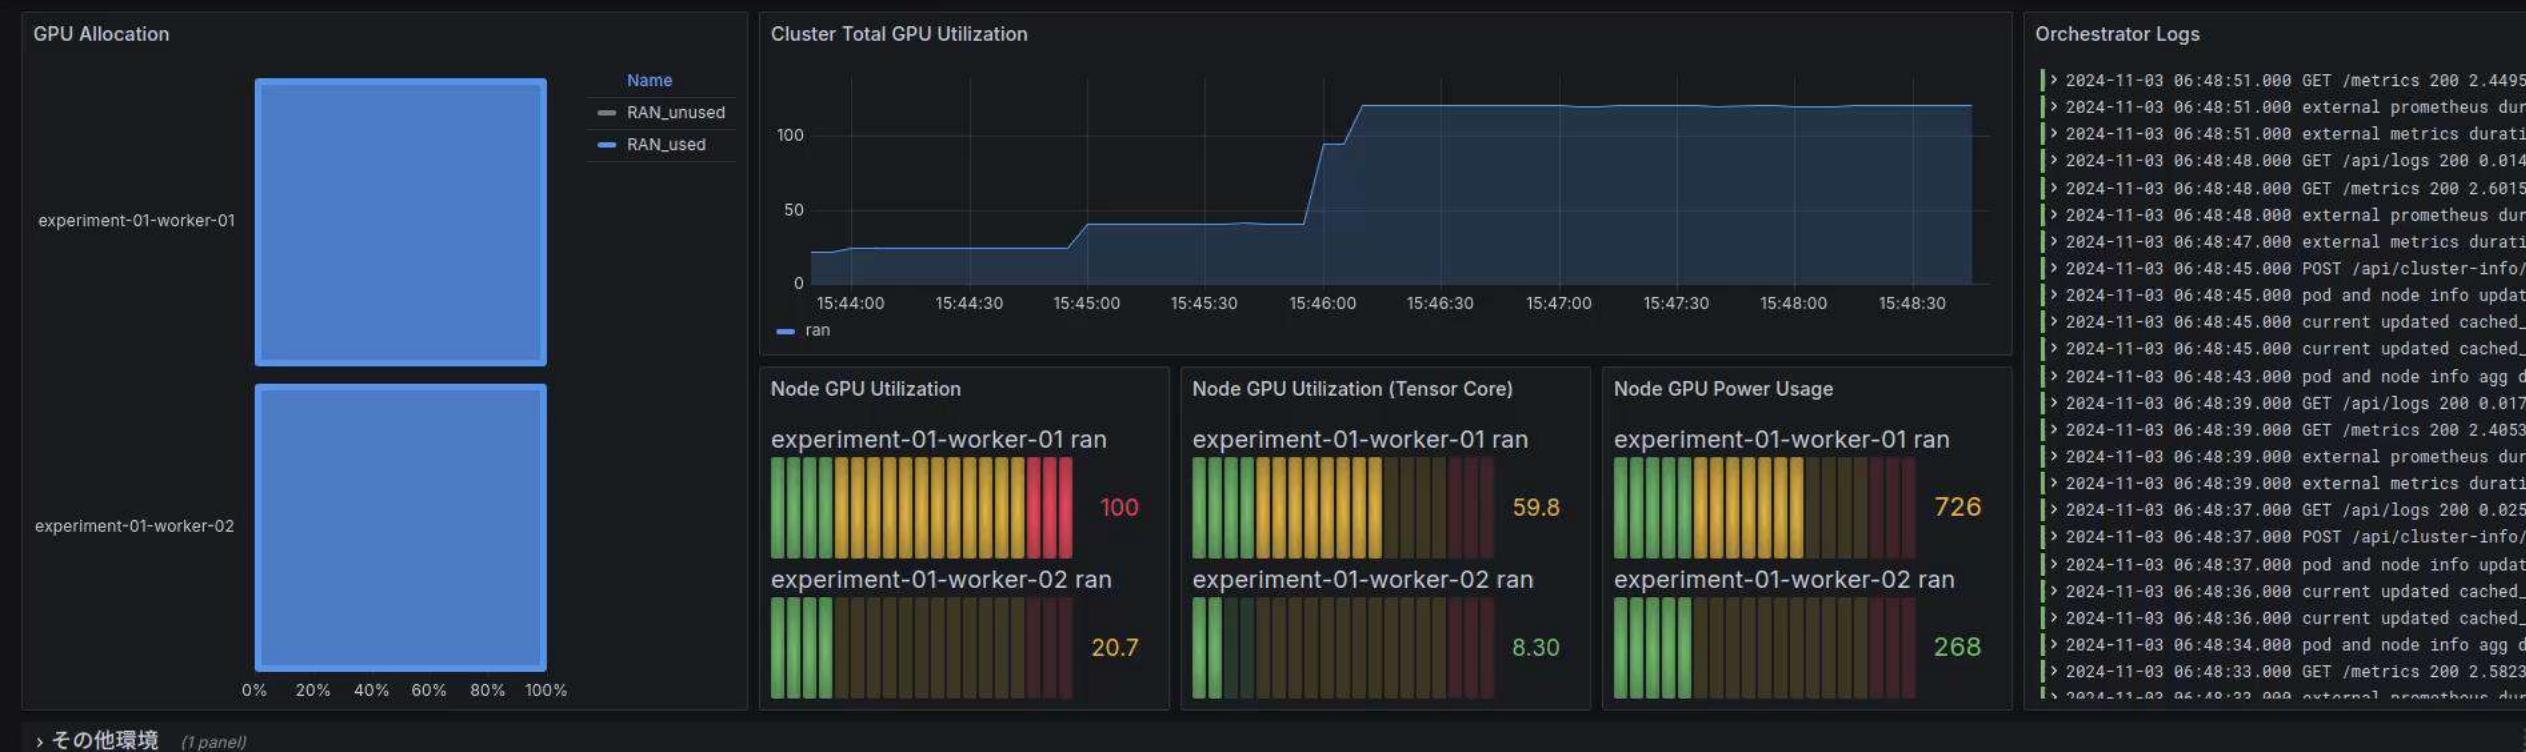
# デモ画面のご紹介

## ノードの種別・GPU割当状況 GPU使用状況のグラフ



CUDAコア、Tensorコア、  
ノードの消費電力の即時値

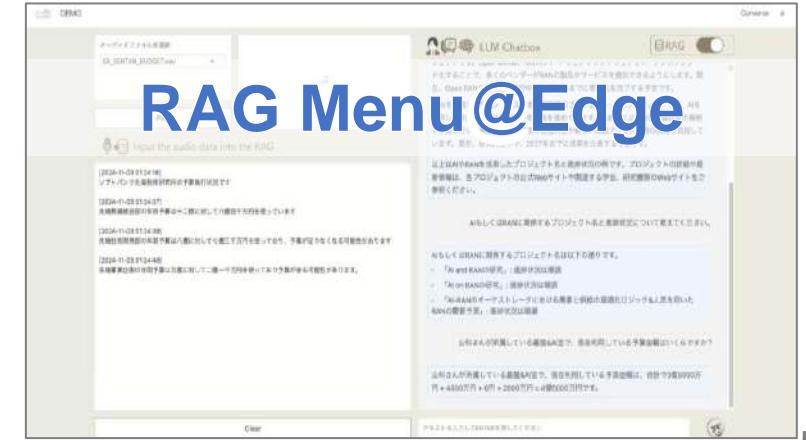
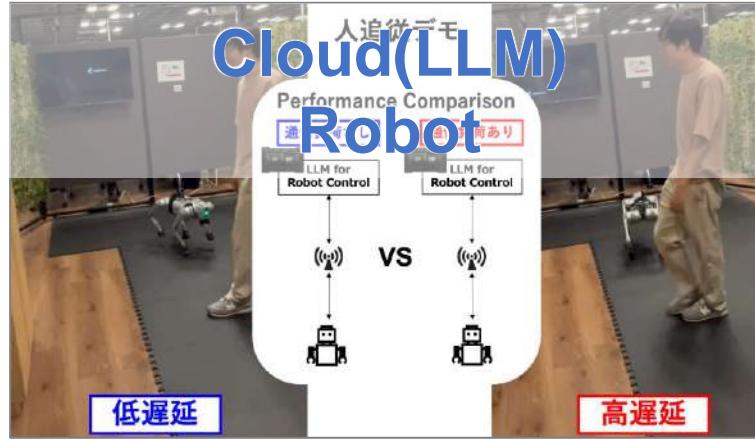
オーケストレーターの  
操作ログ



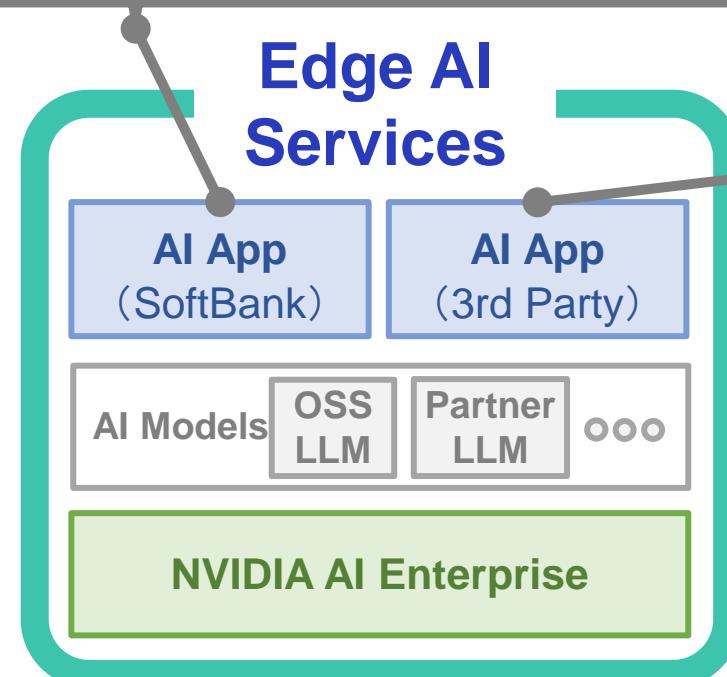
AI-RANオーケストレーターが管理するクラスターに2つのノードが存在し、RANのアプリケーションがそれぞれデプロイされています。

# NVIDIA AI Enterprise@AITRAS を用いたユースケース

SoftBank



本日デモで  
ご説明予定



Serverless API powered  
by NVIDIA AI Enterprise  
@edge

