

多様なAI半導体の活用と計算資源の効率化に関する研究開発

実施者	国立研究開発法人産業技術総合研究所、1FINITY株式会社、株式会社AI福島、株式会社ELEMENTS、富士通株式会社、株式会社テプコシステムズ、株式会社RUTILEA、株式会社ゼウレカ
概要	AIの開発力・供給力を支える国内計算基盤の高度化のため、 <u>多様なAI半導体の評価と計算資源の効率化を実現する技術</u> を研究開発する。高性能化や低消費電力が期待されている複数の新興AI半導体からなるテストベッドを整備し、 <u>その性能や省電力性、AI開発の利便性、運用性等の多面的な評価</u> を行い、用途に応じた利活用指針を明らかにする。また、それらAI半導体を含む計算資源の効率化として、 <u>AIワークロードの実行性能予測や高効率・高性能推論システム</u> を開発する。

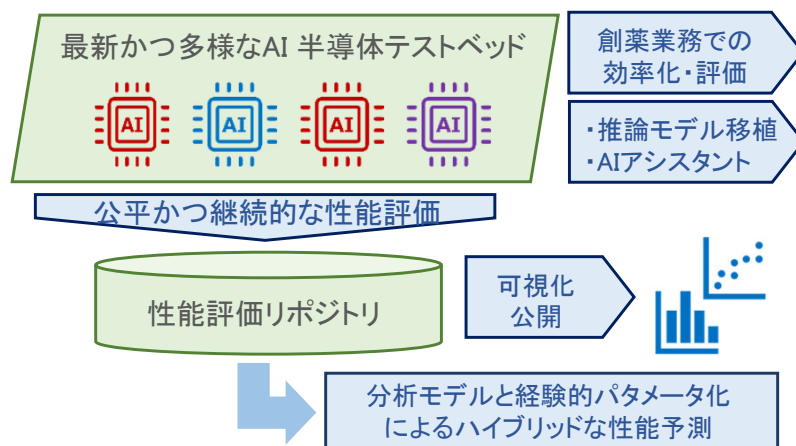
【①多様なAI半導体の評価と効率的な利用技術の研究開発】

- 多様かつ最新のAI半導体の特性・優位性を明らかにするテストベッド構築と公平なAIベンチマークセットの開発
- 実業務(創業ワークロード)での効率的な利用技術の開発
- 多様なAI半導体での推論モデル移植・実行技術及び生成AIによるアシスタント機能の高度化

【②大規模計算資源利用の効率化技術の研究開発】

②-1) 実行性能予測に基づく資源利用の効率化

- 学習／推論の高精度な実行性能予測技術の開発
- 学習／推論処理の継続的な性能評価と性能予測用データセットの高度化



②-2) 高効率・高性能 推論システムの研究開発

- 入力データ選択制御：多種多様なデータソースからの入力データ量の削減とクエリ処理の効率化・高速化技術の開発
- LLM推論API：日本語とデータ操作言語を組合せた入力に対し投機的デコーディングによる適切な推論エンジン選択技術の開発
- 構成管理ソフト：需要変動に基づく、推論基盤モデル向け計算資源構成の動的適正化技術の開発
- スケジューラ：AI半導体の利用効率を上げる高度なスケジューリング技術の開発
- KV Cacheオフロード：LLM推論のスケラビリティ向上と効率化に向けた設計指針の確立

