

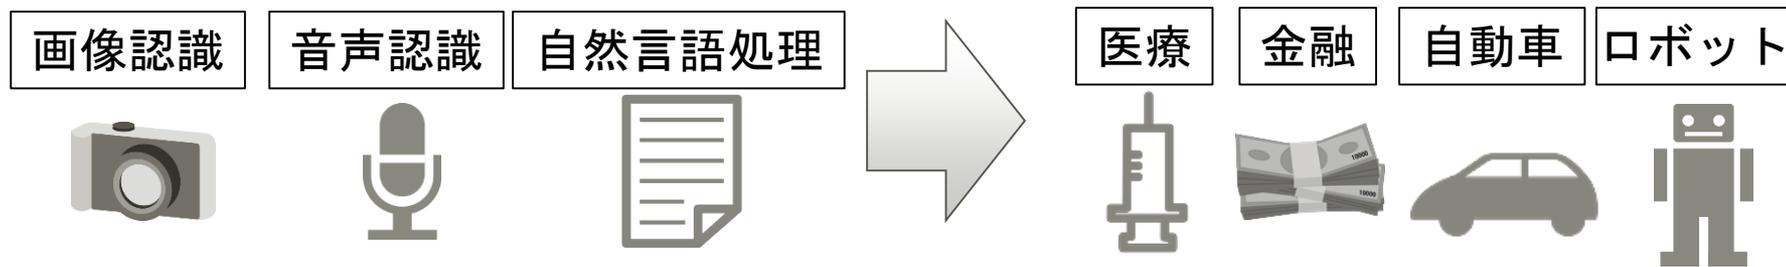
大規模ニューラルネットの高速 Deep Learningの実現に向けて

株式会社富士通研究所

白幡 晃一

k.shirahata@jp.fujitsu.com

■ Deep Learningは様々なアプリケーションへ適用拡大



■ ニューラルネットの大規模化

ニューラルネットの層数は増えるほど認識等の精度向上のため、大規模化が進む

年	ネット名	層数	エラー率
2012	AlexNet	8	16.4%
2014	VGGNet	19	7.3%
-	人間	-	5.1%
2015	ResNet	152	3.6%
2016	Ensemble 2	~152	3.0%

学習時間が増大 → 複数GPUの並列動作による高速化が必要

メモリ使用量が増大 → GPUメモリ使用の効率化が必要

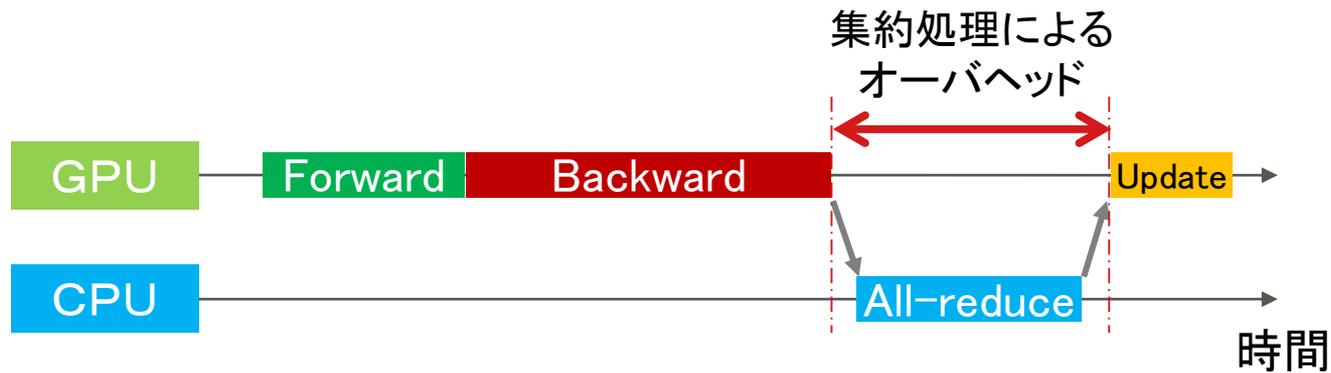
Deep Learning処理の大規模 並列化による高速化技術

複数ノードで行う学習処理の課題

- All-reduce処理が加わる事でGPUが動作しない時間が発生

「重みパラメタの要素数」が多い場合、大きくなる

「ノード数」の増加に伴い、大きくなる



基本的なアイデア

- ・集約処理時間を他のGPU処理時間に隠蔽
- ・集約処理時間を短縮

Backward処理時間への隠蔽

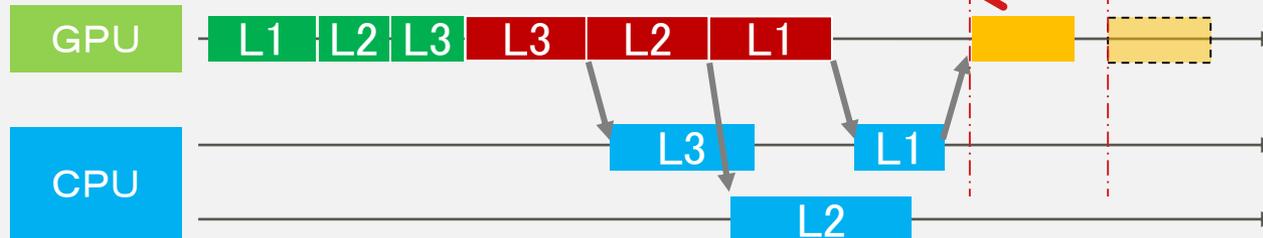
方法

各層のBackward処理が終わるごとに
層単位でAll-reduce処理を開始する



Backward処理とAll-reduce処理を
並列に実行することで高速化

隠蔽後



Forward処理時間への隠蔽

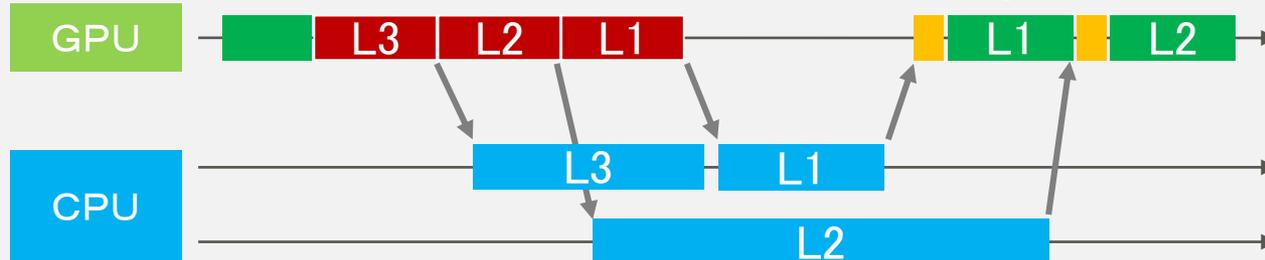
方法

- Update処理を**分割**
- Forward処理の開始を**層ごと**に判定

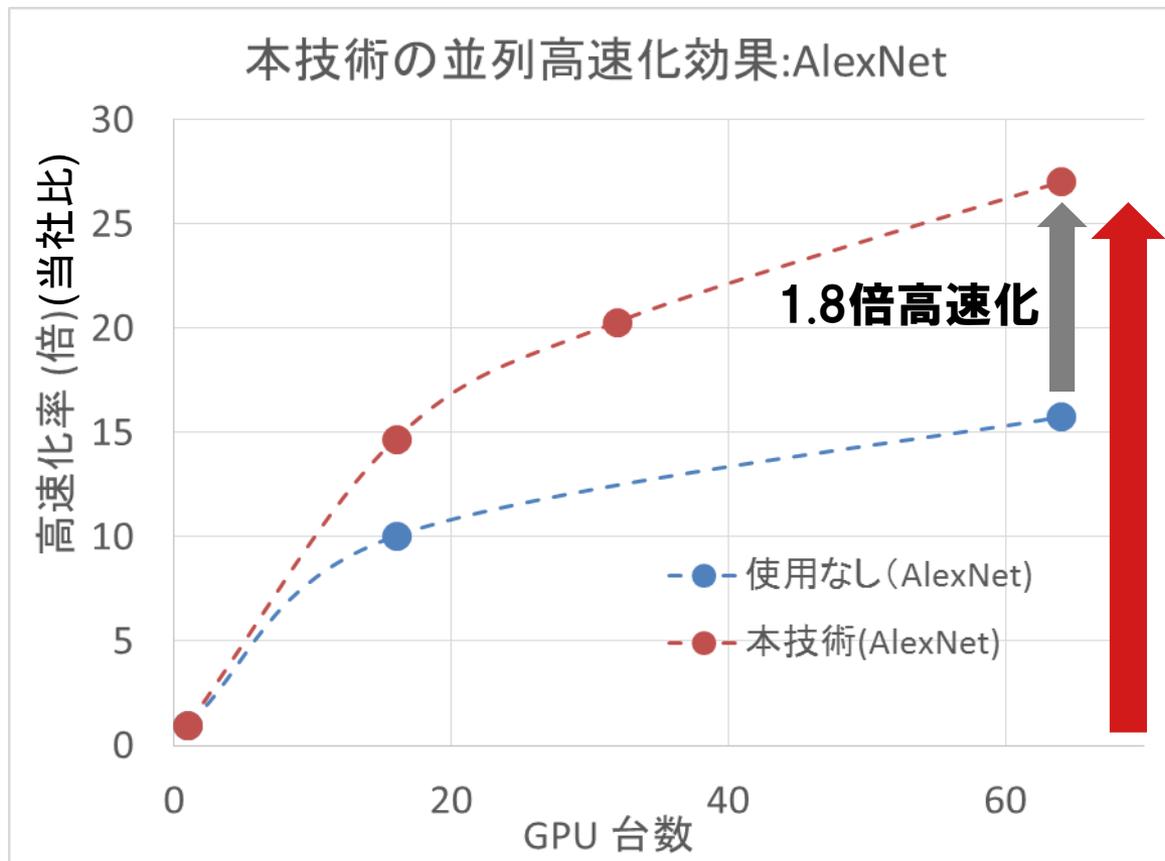


層単位でUpdate処理

すべての層のAll-reduce処理の完了前に、次のForward処理を開始することで高速化



複数 GPU 使用時の 1 GPU 使用時に対する学習時間の高速化率



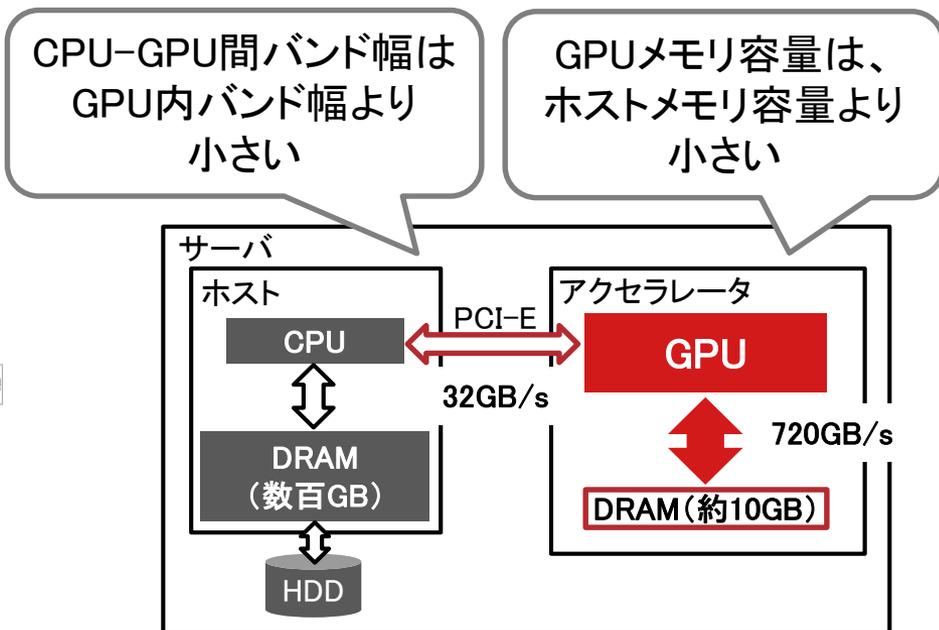
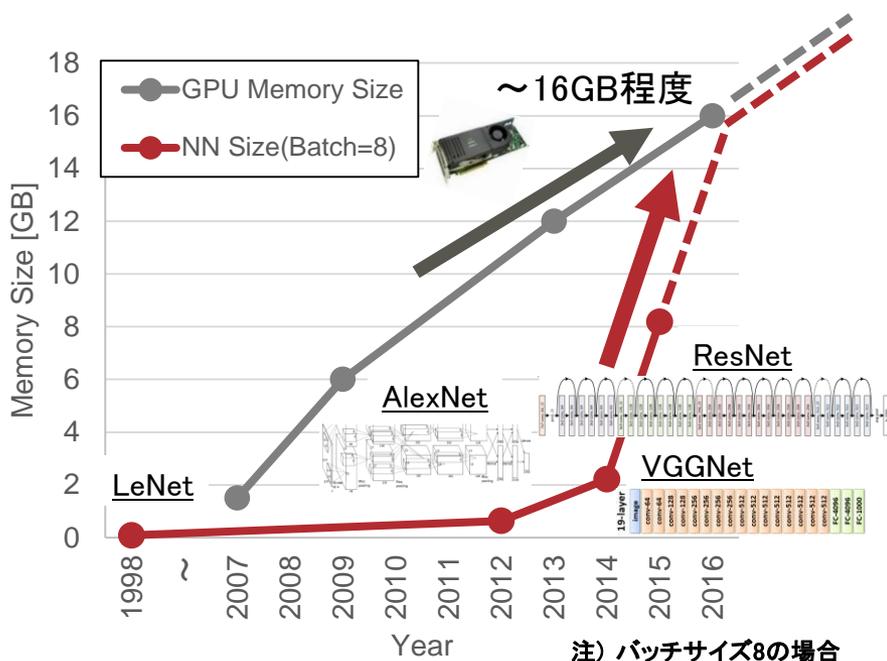
評価環境

- ・Tesla K20X GPU を 64 GPU (1ノードあたり1GPU) まで使用

Deep Learningのニューラルネットを 拡大するメモリ効率化技術

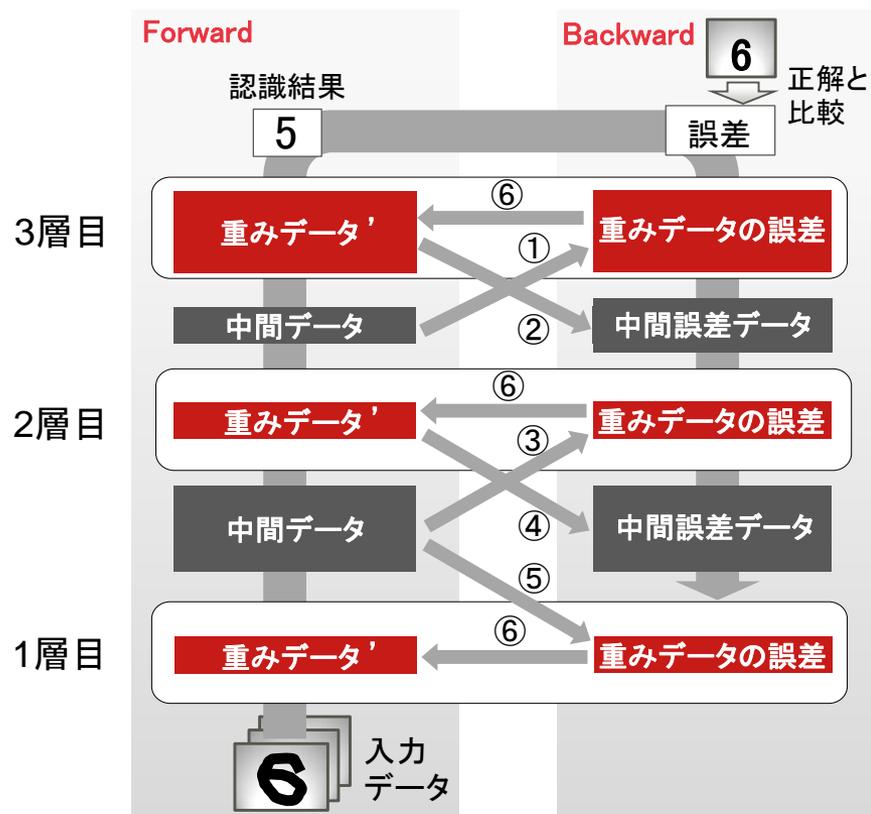
GPUを用いたDeep Learningの現状

- ニューラルネットの規模は年々急速に拡大
- GPUの高速な演算性能を活用するには、一連の演算に使用するデータを可能な限りGPUの内部メモリに格納する必要がある



GPUが搭載しているメモリ量が小さいため、高速に学習できるニューラルネットの規模が制限されるという課題がある

■ 学習時にGPUのメモリ使用量が増加する



①と②、③と④はそれぞれ独立に演算可能

重みを更新するための**重みデータの誤差**と、誤差を前層に伝えるための**中間誤差データ**を計算

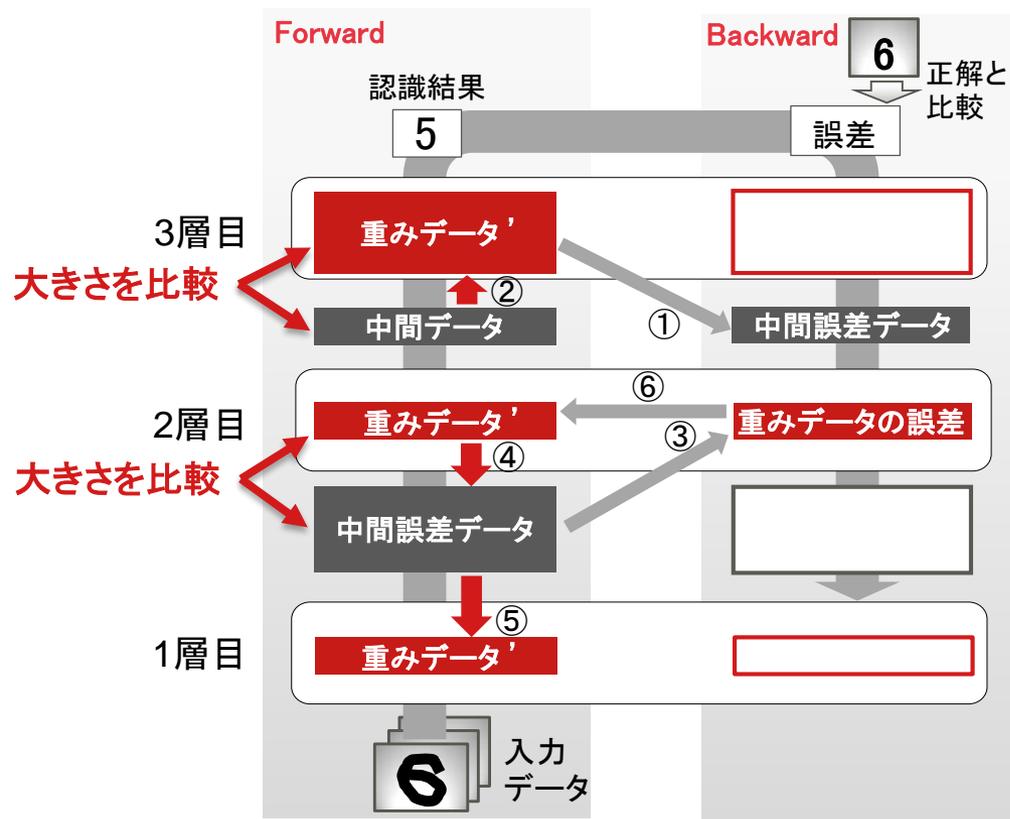
重みデータ、中間データに加えて**誤差データを確保**

基本的な
アイデア

- ・2種類の誤差データ計算の独立性に着目
- ・メモリ領域の再利用によりメモリ使用量を削減

方法

ニューラルネットの構造を解析し、より大きなメモリ領域を再利用するように演算順序とメモリ配置をスケジューリング

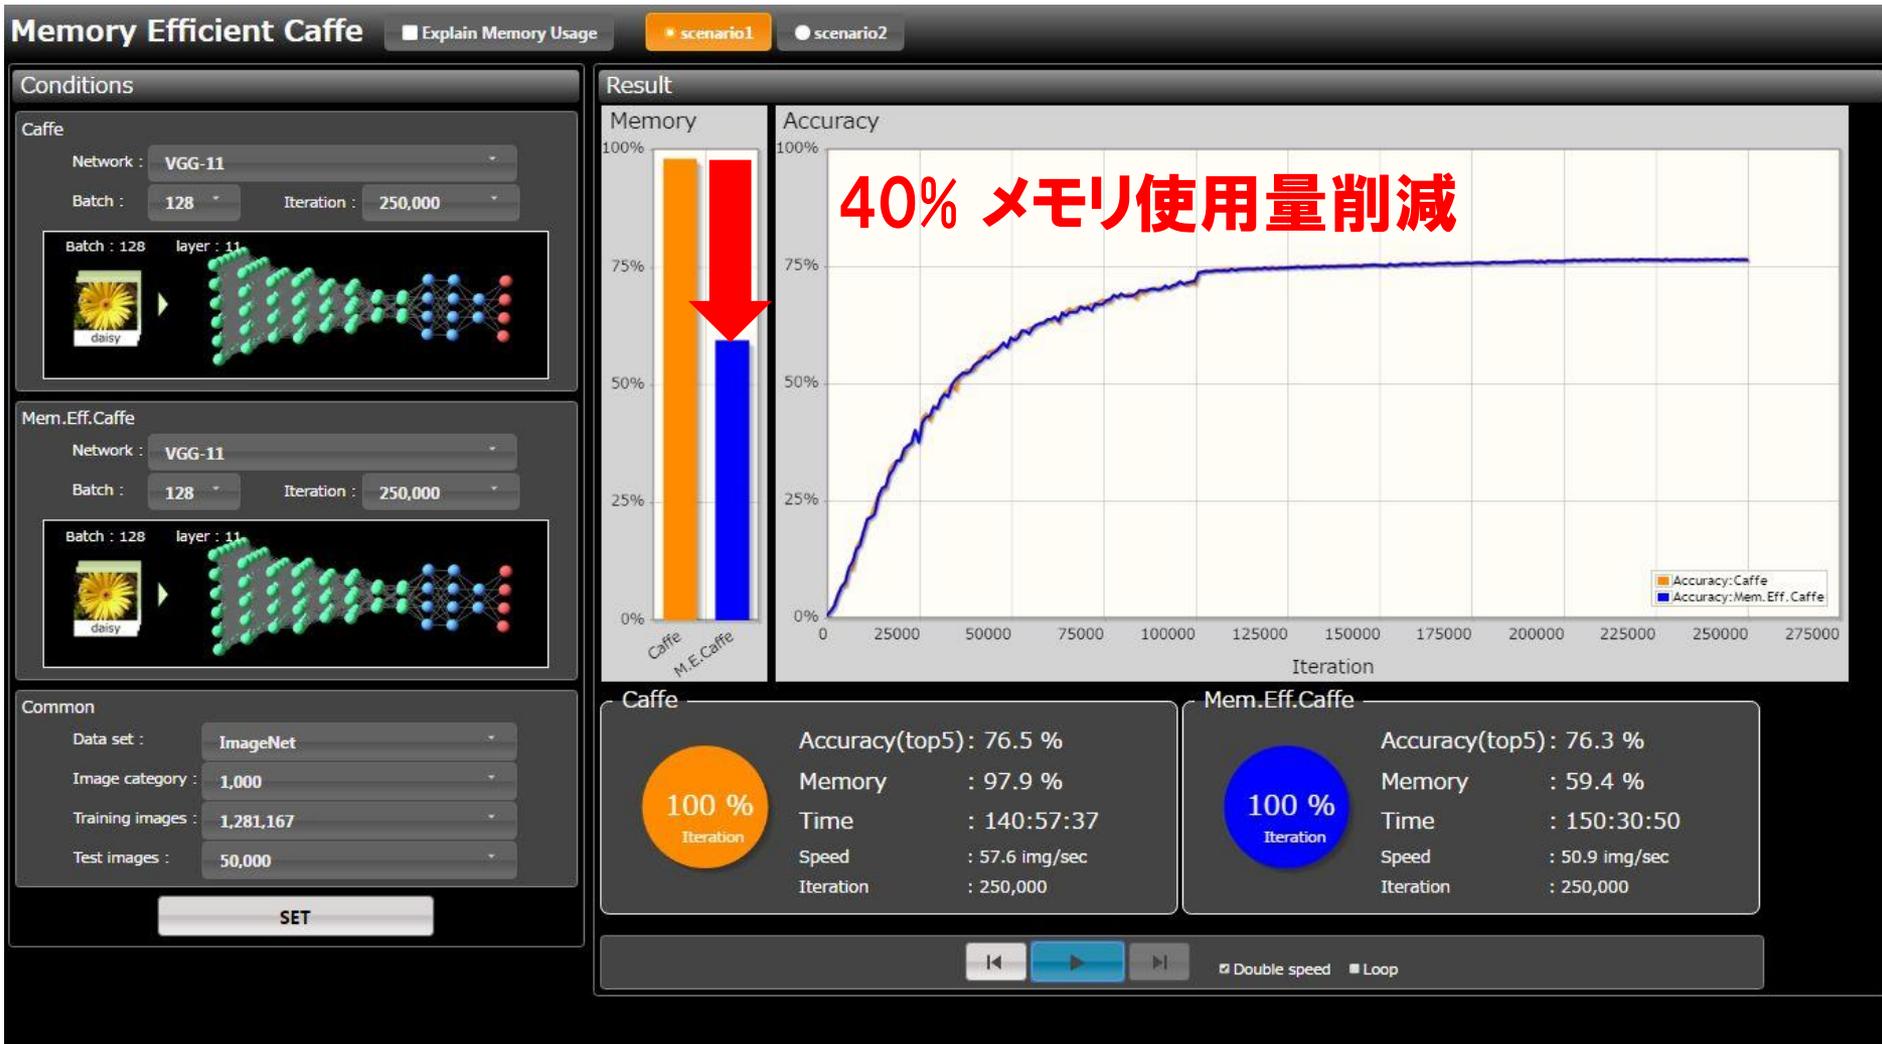


重みデータ > 中間データの層 (Fully-connected層など) では、**重みデータ領域を上書き**してメモリ使用量を削減

中間データ > 重みデータの層 (Convolution層など) では、**中間データ領域を上書き**してメモリ使用量を削減

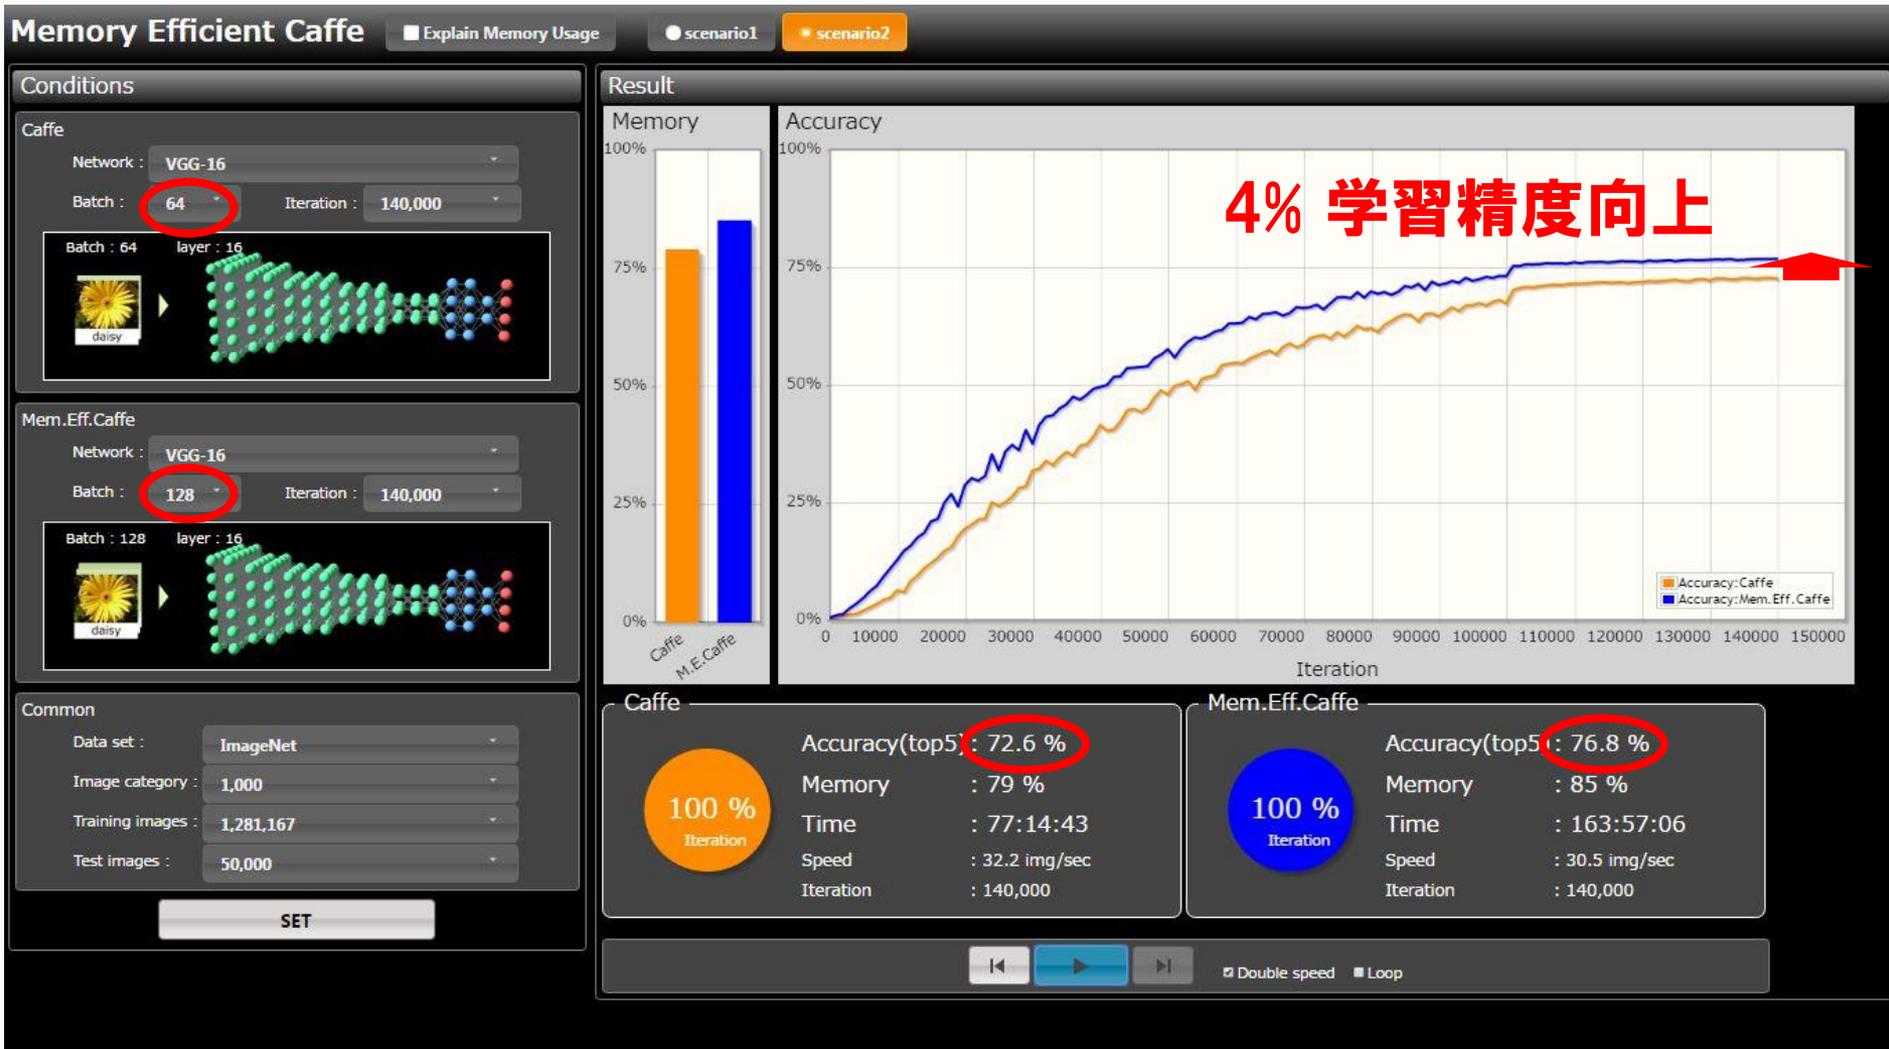
評価: メモリ効率化Caffe

■ 同じニューラルネット(VGGNet)を使用し、同条件で比較

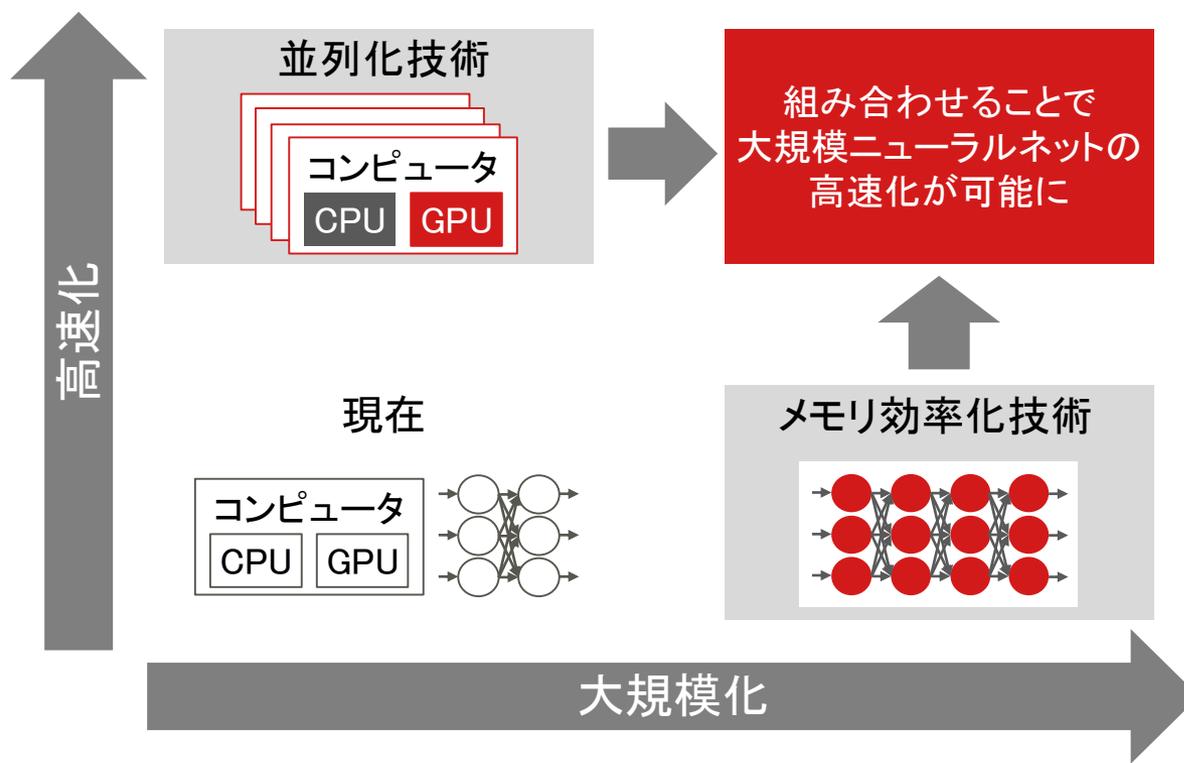


評価: メモリ効率化Caffe

■ 削減したメモリ領域を活用してミニバッチサイズを2倍に拡大



- 今回紹介した技術は富士通株式会社のAI技術「Human Centric AI Zinrai(ジンライ)」の一つとして、2017年4月から順次実用化を予定
- 「Deep Learning処理の高速化技術」と「メモリ効率化技術」を組み合わせ、技術の改善を行う





FUJITSU

shaping tomorrow with you