

TSUBAME 共同利用 令和 2 年度 学術利用 成果報告書

利用課題名 HPC を利用した自然言語処理技術の研究

英文: High Performance Computing for Natural Language Processing Technology Research

利用課題責任者

鳥澤 健太郎

所属

国立研究開発法人情報通信研究機構 ユニバーサルコミュニケーション研究所

データ駆動知能システム研究センター

<http://www2.nict.go.jp/direct/>

邦文抄録(300 字程度)

本課題では、課題責任者らが開発を進めてきた、大規模ニューラルネットワーク学習のための自動並列化深層学習ミドルウェア RaNNC について、TSUBAME の計算資源を用いながら、主に通信部のチューニングと動作検証を実施した。RaNNC は、ニューラルネットワークを分割するモデルパラレルと呼ばれる並列化を自動化する機能を持つ。別途実施した課題責任者らの所属組織の計算資源を用いた機能強化と合わせ、包括的なチューニングを進めた結果、同じくモデルパラレルによる並列学習を行うフレームワークである Megatron-LM と比較して、約 5 倍のパラメータを持つニューラルネットワークを学習できること、両方が学習可能な規模のニューラルネットワークでは、ほぼ同等の学習速度であることを確認した。また、RaNNC の動作検証を通じて堅牢化を進め、ソースコードを GitHub に公開した。

英文抄録(100 words 程度)

In this project, we improved the efficiency of communication of RaNNC, automatic parallelization middleware for training very large-scale neural networks, and tested RaNNC's features using TSUBAME. RaNNC automatically partitions a neural network for model parallelism. After we performed comprehensive performance tuning using TSUBAME and our clusters, we compared RaNNC with some existing frameworks. The experimental results showed that RaNNC can train models five times larger than Megatron-LM, a well-known framework for training very large neural networks with model parallelism, and RaNNC's training throughputs are comparable to Megatron-LM's when training the same models. We also improved the robustness of RaNNC through tests using TSUBAME and released the source code on GitHub.

*Keywords:* 自然言語処理, 大規模ニューラルネットワーク学習, モデルパラレル

#### 背景と目的

近年、深層学習で用いられるニューラルネットワークの大規模化が進んでいる。例えば言語処理分野では、2018 年に Google から発表された BERT[Devlin 2018]を端緒として、事前学習を用いる極めて大規模なパラメータを持つニューラルネットワークが次々に発表されてきた。著名な例では、GPT-3[Brown 2020]と呼ばれるネットワークは、約 1750 億ものパラメータを持つ。

深層学習で広く用いられる、データパラレルと呼ばれる並列化方式は、ネットワーク全体を複製するため、こうした巨大なニューラルネットワークは困難である。そこで、我々はネットワークを分割するモデルパラレルを自動的に行うミドルウェア RaNNC (Rapid Neural Network Connector) を開発してきた。

当年度は、ニューラルネットワーク分割アルゴリズムの改善やパイプライン並列の導入によって、RaNNC の学習速度と学習可能なニューラルネットワークの規模を大幅に向上させてきた。本課題では、TSUBAME の計算資源を用いながら、各種のチューニングを行うことで学習速度を向上させると共に、動作検証を重ねることによって RaNNC の堅牢性の向上を目指した。

#### 概要

TSUBAME は Intel Omni-Path による高速なノード間接続を備えているため、本課題では、TSUBAME の計算資源を用いながら、主に通信部分に関する RaNNC のチューニングを進めた。また TSUBAME は、仮想化によりノードが持つ GPU の一部のみを利用可

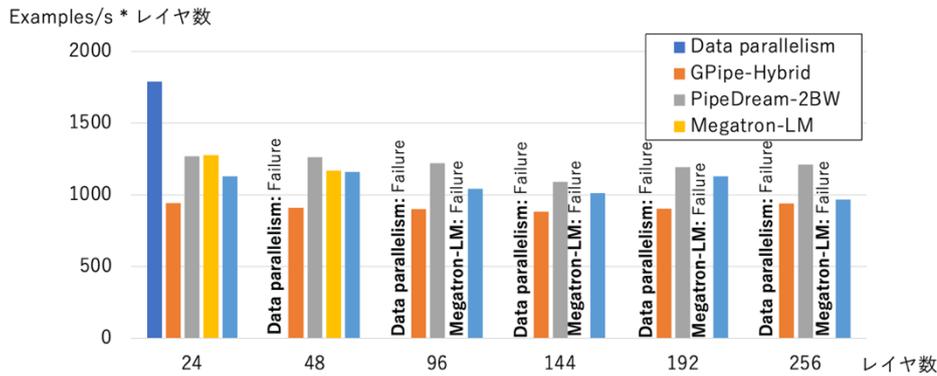


図 1 大規模 BERT モデル(隠れ層サイズ 2048)におけるスループット比較

能とする機能を持つため、様々な GPU 数での動作検証を行った。

#### 結果および考察

RaNNC の有効性を評価するため、類似の関連フレームワークとの比較実験を行い、大規模化した BERT の事前学習でのスループットを調査した(図 1)。なお、以降に示す実験では、TSUBAME を用いたチューニングに加え、ニューラルネットワーク分割アルゴリズムの改善や、課題責任者らの所属組織の計算資源を用いたチューニングなど、別途実施した機能強化を包括的に適用している。また、必要リソース量の問題から、本実験は課題責任者らの所属機関の計算資源で実行した。InfiniBand により 100Gbps で接続され、NVIDIA V100 を 8 枚備えたサーバ 4 台を用いている。

BERT の隠れ層サイズは 2048 に設定し、レイヤ数を最大 256 まで拡張した(BERT の原論文では、隠れ層サイズは 1024, レイヤ数は 24)。256 レイヤの設定において、パラメータ数は 129 億に達する。バッチサイズは 256, 系列長 512, 数値精度は FP32 に設定した。

比較対象として、データパラレルのみの設定の他、GPipe[Huang 2018]、Megatron-LM[Shoeybi 2019]、PipeDream-2BW[Narayanan 2020]と比較した(GPipe は原論文ではモデルパラレルのみを行う手法が提案されているが、ここでは PipeDream-2BW の著者らによるデータパラレルと併用する実装を用いた)。

図 1 に示すように、RaNNC は最大で Megatron-LM の 5 倍のモデルを訓練できた。また同一条件で訓練できた場合では、ほぼ同等のスループットを得た。また、GPipe と比較すると、全ての設定でより優れたスループットを得られた。PipeDream-2BW と比較すると、

幾分スループットが低い結果となっているが、PipeDream-2BW は、RaNNC を含むその他のフレームワークと異なり、分割されたニューラルネットワーク間でパラメータの同期を省くことで高速化しているため、学習精度が低下する可能性があるという問題がある。

また、TSUBAME 上での各種の動作検証を通じて、RaNNC の堅牢性を向上させ、RaNNC のソースコードを GitHub に公開した。

#### まとめ、今後の課題

当年度実施した、実行速度とスケーラビリティに関する RaNNC の改善を、他のフレームワークとの比較を通じて評価し、訓練速度と学習可能なネットワーク規模の両方において、優れた性能を確認した。

今後、更に大規模なニューラルネットワークを学習するための機能強化を進めると共に、言語処理分野を中心とした各種の大規模ニューラルネットワークに適用し、有効性を検証していく予定である。

#### (参考文献)

- [Brown 2020] T. B. Brown et al., Language Models are Few-Shot Learners, arXiv:2005.14165, 2020.
- [Shoeybi 2019] M. Shoeybi et al. Megatron-LM: Training Multi-Billion Parameter Language Models Using Model Parallelism. arXiv: 1909.08053, 2019.
- [Huang 2018] Y. Huang, GPipe: Efficient training of giant neural networks using pipeline parallelism, arXiv: 1811.06965, 2018.
- [Narayanan 2020] D. Narayanan et al., Memory-Efficient Pipeline-Parallel DNN Training, arXiv:2006.09503, 2020.