

РАСПРЕДЕЛЕННОЕ ОБУЧЕНИЕ ГЛУБОКИХ НЕЙРОННЫХ СЕТЕЙ: ОГРАНИЧЕНИЯ МАСШТАБИРУЕМОСТИ

Варвашевич М.С., Леончик А.Л.

Научный руководитель – Прихожий А.А., профессор, д.т.н.

Чтобы эффективно решать задачи, глубокие нейронные сети (DNN) необходимо обучать с использованием большого количества данных и вычислительных ресурсов. На данный момент уровень развития техники позволяет осуществлять распараллеливание задачи обучения между 8-ю и более процессорами, размещенными в одном вычислительном узле. Известные методы распределения [1], [2] показывают неутешительные результаты [3] с точки зрения масштабируемости и эффективности. На рисунке 1 (слева) видно, что прирост скорости обучения сети в зависимости от ее масштабирования практически останавливается уже после нескольких десятков узлов.

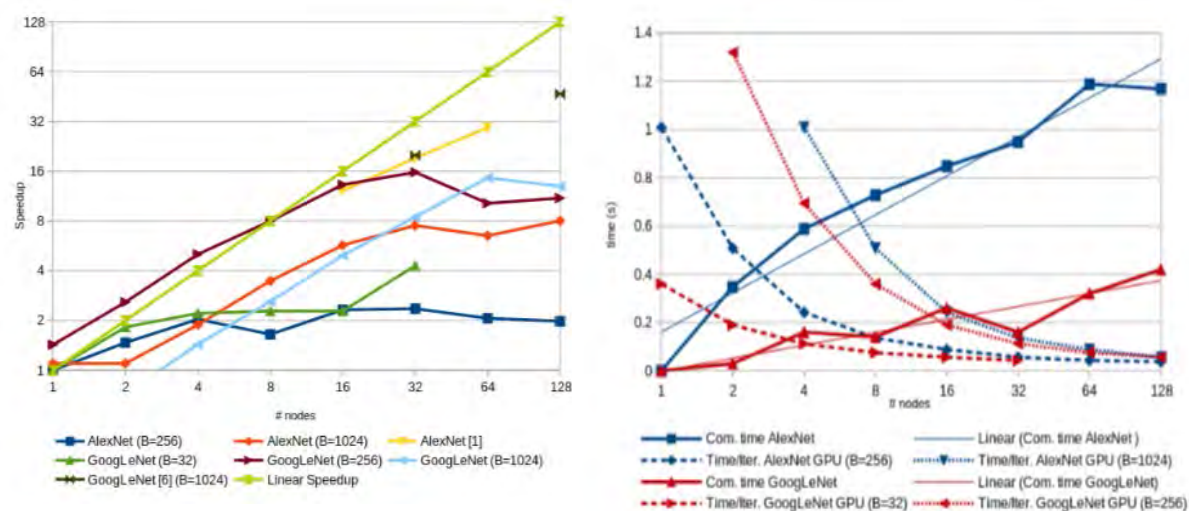


Рисунок 1. Экспериментальная оценка масштабируемости обучения DNN с различными размерами пакета (слева). Коммуникационные издержки для разных моделей (справа). Масштабируемость останавливается, когда время вычислений ниже времени обмена данными, в результате чего вычислительные блоки простаивают

DNN обучаются с использованием алгоритма стохастического градиентного спуска (SGD). Распараллелить данный алгоритм достаточно сложно - это связано с его последовательной природой. Для распределенной

реализации на многопроцессорных системах обычно используется версия SGD с параллелизмом данных.

1. Накладные расходы распараллеливания

Распараллеливание обучения DNN с помощью SGD требует синхронизации модели и вычисления градиентов между всеми узлами на каждой итерации. Так как вычисление весов должно быть синхронизировано на всех узлах, вся коммуникация между узлами должна быть завершена до следующей итерации. Таким образом, более быстрые вычислительные ресурсы (например, более мощные GPU) усугубляют фундаментальную проблему, которая заключается в том, что время связи превышает время вычислений после масштабирования всего до нескольких узлов, заставляя вычислительные ресурсы простаивать.

На рисунке 1(слева) показана разница между временем на коммуникацию и на вычисления. В зависимости от размера модели, проблема обучения становится зависимой от времени на коммуникацию после масштабирования всего лишь от 4 до 8 узлов. Это напрямую коррелирует с общими результатами масштабирования, показанными на рисунке 1(слева).

В последнее время было предложено несколько подходов для преодоления этой проблемы: например, некоторые методы пытаются уменьшить размер модели перед коммуникацией. Это может быть сделано путем (а) перепроектирования сети - устранения неиспользуемых весов, (б) ограничения точности вычисления весов модели, (с) сжатия (которое описано в [1]) или (д) передачи только разряженного градиента и информации о модели [4]. Все эти методы оказывают реальное влияние, перемещая масштабируемость на коэффициент уменьшения размера модели. Но ни один из этих подходов не способен решить проблему в принципе, поскольку размеры моделей увеличиваются намного быстрее, чем доступная пропускная способность сетей.

2. Параллельный доступ к обучающим данным

Другим узким местом в распределенном обучении глубоких нейронных сетей является распределение обучающих данных между узлами системы. Хранение копии всех обучающих данных на каждом узле системы не только требует наличия NVRAM (или другого высокоскоростного локального хранилища) на каждом узле, но также требует высокой производительности в силу необходимости копировать сотни гигабайт на каждый узел непосредственно перед самим обучением DNN.

2.1. Увеличение пропускной способности сети

Использование централизованного хранилища для обучающих данных является более эффективным решением, чем хранение больших наборов данных непосредственно на локальных узлах. По сравнению с петабайтами трафика, вызванного распределением SDG, нагрузка от распределения обучающих данных кажется пренебрежимо малой. На рисунке 1 (справа) представлены практические последствия хранения обучающих данных в распределенной файловой системе Lustre, когда пропускная способность сети превышена коммуникациями SDG.

2.2. Небольшие файлы – высокоскоростной произвольный доступ

Пропускная способность - не единственная проблема, когда дело доходит до использования параллельных файловых систем. Есть также проблемы с задержкой, которая обусловлена структурой обучающих данных, используемых во многих приложениях глубокого обучения: как правило, обучающие данные представлены большим количеством небольших файлов (например изображения, аудио или тексты), которые должны быть доступны случайным образом в течение времени, необходимого для обучения нейронной сети. Множество узлов одновременно опрашивают большое количество случайных файлов на сервере с файловой системой, что приводит к тому, что сервер начинает отвечать с задержкой, или вовсе к падению распределенной файловой системы.

Заключение

В данном докладе мы показали два конкретных узких места в масштабируемом распределенном обучении DNN, которые должны быть преодолены для получения устойчивого решения, которое может обеспечить масштабирование на тысячи узлов. В настоящее время, эффективное масштабирование при распределенном обучении DNN невозможно на числе узлов, превышающем 16.

Литература

1. <https://github.com/intel/caffe> [Электронный ресурс] / IntelCaffe – Электрон. дан. - Режим доступа: <https://github.com/intel/caffe>, свободных – Загл. с экрана – Яз. англ. (дата доступа 14.04.2020)
2. Tensorflow: Large-scale machine learning on heterogeneous distributed systems. arXiv preprint, M. Abadi – Препринт arXiv - arXiv:1603.04467, 2016.
3. On parallelizability of stochastic gradient descent for speech dnns, F. Seide – В разделе 2014 IEEE International Conference on Acoustics, Speech and Signal Processing (ICASSP), стр. 235–239. IEEE, 2014.
4. Scalable and sustainable deep learning via randomized hashing, R. Spring and A. Shrivastava. - Препринт arXiv - arXiv:1602.08194, 2016.