如何评价Google的GShard论文？ - 知乎

https://www.zhihu.com/question/404721763/answer/2111040851

袁进辉开发深度学习编译器，框架及平台OneFlow Thu Sep, 09 20:15

GShard 最早于2020.6.30 放在arXiv上 GShard: Scaling Giant Models with Conditional Computation and Automatic Sharding 2006.16668.pdf (arxiv.org)

还有一篇更系统的系统论文

GSPMD: General and Scalable Parallelization for ML Computation Graphs (arxiv.org)

文章包含两部分的工作，一部分是并行API，一部分是Mixture of experts，比较有意思的是前一部分，我只讨论这部分，这部分的贡献在论文摘要里概括的很清楚：

GShard is a module composed of a set of lightweight annotation APIs and an extension to the XLA compiler.

我也不打算过多介绍文章的细节，这些内容在原论文里都可以看到，只介绍一些背景信息，以及从我们在oneflow里做过的类似工作来评价一下GShard还有哪些可改进的地方。只有把GShard放在上下文里去看时，才能更清楚的看到它的好和不好。

这要从数据并行和模型并行说起，先列一下，我知道的在GShard之前的相关工作

1，这也许是最早探讨模型并行的文章，2014年发表在arXiv上

Alex Krizhevsky (没错，就是AlexNet那位）， One weird trick for parallelizing convolutional neural networks 1404.5997.pdf (arxiv.org)

这篇文章最大的洞见是发现不同的层适合用不同的并行方式，具体的，卷积层数据比参数大，适合数据并行，全连接层参数比数据大，适合模型并行。

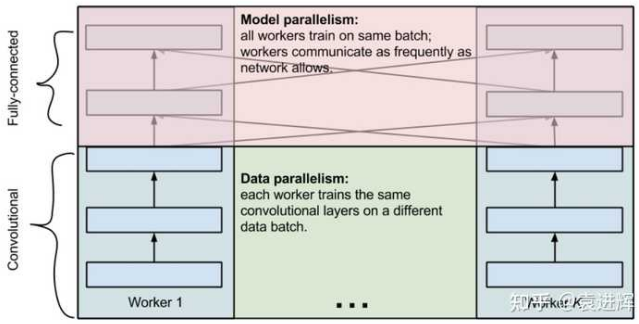

最早是在cuda-convnet 这个软件上实现的，史前的深度学习框架，现在知道这套软件的人比较少了。

2，Zhihao Jia 发表过2篇在这个方向上很有影响力的文章

Exploring Hidden Dimensions in Parallelizing Convolutional Neural Networks

发表于2018年ICML，Alex前面那篇文章直观的提出来，有的层次适合数据并行，有的层次适合模型并行，那么给定一个神经网络，有没有自动的办法找到最优的并行办法呢？ Zhihao Jia这篇文章就是想解决这个问题。

首先，这篇文章在抽象上更进一步，发现数据并行，模型并行都只是张量切分方式的不同罢了，有的是切数据，有的是切模型，而且对于多维张量，在不同的维度上切分，效果也不同，譬如在sample, channel, width, length等维度都可以切分。

其次，不同的切分方式，都是一种构型（configuration），不同的构型会导致不同的效果，所以寻找最优的并行方式，其实就是在构型空间里面搜索最优的构型而已，问题形式化成一个搜索问题。

最后，引入了代价模型来衡量每个构型的优劣，并提出了一系列对搜索空间剪枝的策略，并实现了原型系统。

这篇文章勾勒了自动并行的基本框架，很多解决自动并行的工作都是这样一个流程。

Beyond Data and Model Parallelism for Deep Neural Networks

发表于2019年SysML，也就是大名鼎鼎的FlexFlow。这篇文章主要是提出了execution simulator来完善cost model。

在搜索空间的抽象上，我觉得反而有点退步，譬如，上一篇文章的通用的张量切分，这篇反而试图切分方式命名，特别是SOAP (sample, operator, attribute, parameter) 。首先，我认为给切分维度命名是抽象性和一般性的倒退，这也是我觉得下文的Mesh-Tensorflow的不足，也是GShard在抽象上的优势；其次，在概念上的简洁和完备性上不好，也就是SOAP里面有重复的语义，而且也不够完备。

3, Minjie Wang @王敏捷 发表于 2019年EuroSys的Tofu

Supporting Very Large Models using Automatic Dataflow Graph Partitioning (arxiv.org)

这篇文章想解决的问题和Zhihao Jia那两篇文章的问题是一样的，是差不多同期并行的探索，Tofu 提出了一套DSL，方便开发者描述张量的划分策略，使用了类似poly的integer interval analysis来描述并行策略，同样，并行策略的搜索算法上也做了很多很有特色的工作，不过在这里，我主要是关心各项工作是如何抽象搜索空间的。

```
def conv1d(data, filters):
 for b in range(output.shape[0]): #b is batch dimension
   for co in range(output.shape[1]): #co is output channel
    for x in range(output.shape[2]): #x is output pixel
     for ci in range(filters.shape[0]): #di is input channel
      for dx in range(filters.shape[2]): #dx is filter window
       output[b, co, x] += data[b, ci, x+dx]
                           * filters[ci, co, dx]
```

Tofu与所有其它工作的不同之处在于，它的关注点是operator的划分，其它工作的关注点是tensor的划分，二者当然是等价的。不过，我认为关注点放在tensor的划分上更好一些，这不需要用户修改operator的实现，Tofu需要在DSL里描述operator的实现方式。这种区别也会反应到API层面，譬如Mindspore和OneFlow 作为通用框架里少数实现了完整的数据并行、模型并行的系统，在Python API上也不同，在Mindspore训练盘古模型的示例代码里可以看到Mindspore 的划分接口是放在operator上的，相反，OneFlow的SBP体系是把划分接口放在张量上，在operator API上单卡和分布式完全一样。

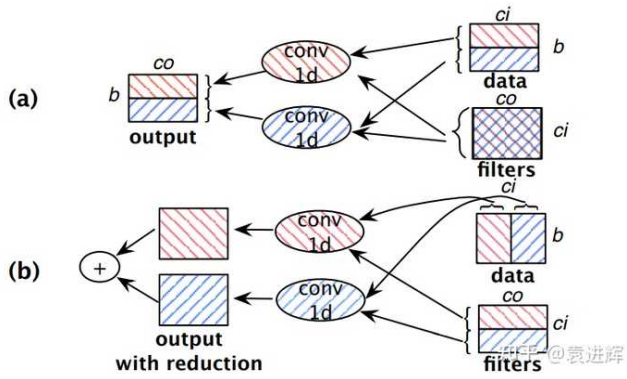

这篇文章讨论了这套解决办法的适用范围，以及有什么问题是解决不了的，这是同类工作种比较难得的。特别是限定了partition-n-reduce的模式，其实GShard也是这种模式。partition and reduce 也包含小小的缺陷，其实partition 之后，不见得”立刻“reduce, 可以让中间的partial结果在系统里继续参与计算，这样反而有可能效率更优，OneFlow的SBP 标注体系之所以引入了P(partial)的原因也在此。

4，Google Brain在NIPS 2018上发表了Mesh-TensorFlow

Mesh-TensorFlow: Deep Learning for Supercomputers [1811.02084.pdf (arxiv.org)]

注意到，Mesh-TensorFlow的作者和GShard的作者几乎是重叠的，Mesh-TensorFlow甚至可以被看作GShard的前身。Mesh-TensorFlow的核心理念也是beyond batch splitting，数据并行是batch splitting，模型并行是张量其它维度的切分。这篇文章把集群的加速卡抽象成mesh结构，提出了一种把张量切分并映射到这个mesh结构的办法。

```
...
batch = mtf.Dimension("batch", b)
io = mtf.Dimension("io", d_io)
hidden = mtf.Dimension("hidden", d_h)
# x.shape == [batch, io]
w = mtf.get_variable("w", shape=[io, hidden])
bias = mtf.get_variable("bias", shape=[hidden])
v = mtf.get_variable("v", shape=[hidden, io])
h = mtf.relu(mtf.einsum(x, w, output_shape=[batch, hidden]) + bias)
y = mtf.einsum(h, v, output_shape=[batch, io])
...
```


我觉得Mesh-TensorFlow的不足主要是需要给张量的维度命名，这种命名是反抽象，会丢失一般性，当然GShard作为后续工作，克服了这个问题，也是GShard的进步之处。

好的，文献综述到此位置，我们总结一下：

1，所有这些工作的目的都是提供一个与编程语言”类型系统“类似的annotation 体系，这个体系需要最简且完备，这个体系定义了”自动并行“的搜索空间。

2，搜索空间中的任何一种构型，也就是任何一种并行策略，在数学上都是正确的，它们的区别仅仅是执行效率不同，我们目的是找到效率最高的并行策略。

3，框架需要这样一种能力，给定任何一种构型，都能翻译和转换成一个物理图（执行计划），确保这个并行策略可以成功执行，即使它的效率不高。

4，框架最好能够自动搜索到效率最高的那个构型。

从这些维度来考察所有这些工作，我们就可以对每一件工作做出评价，当然也可以评价GShard。

GShard 提供了3种类型的标注，即

- **replicate(tensor)** annotates `tensor` to be replicated across partitions, and returns the annotated tensor. This is often used for the non-MoE layers in our model to replicate the weights.
- **split(tensor, split_dimension, num_partitions)** annotates `tensor` to be partitioned along `split_dimension`, and returns the annotated tensor. Partition i is placed on the i'th device, and `num_partitions` must not exceed the number of devices on the system.
- **shard(tensor, device_assignment)** generalizes `split()` to allow partitioning multiple dimensions and specifying the placement of each partition. Appendix A.3 describes this API with more details.

与OneFlow的SBP相比，我认为GShard是有一些不足的。

首先，这个定义有点冗余，split和shard实际上是一回事，不过split 仅仅是在一个维度切分，shard可以在多个维度切分，OneFlow里的broadcast和GShard replicate完全对应，OneFlow的split 和GShard的split, shard 对应，不过OneFlow把split拓展到了多维，1D split 与 GShard split等价，ND split 与GShard shard 等价。

其次，这个定义也不完备，缺少OneFlow SBP里的Partial的概念，这样当系统中有局部计算结果时，就要立即通过规约操作进行处理，得到完整的结果（If the inputs are partitioned along contracting dimensions, the local result is partial and we need to use an AllReduce to combine them and produce the final result）。但实际上，有些局部计算结果是仍然可以参与下游的计算也是合法的，可以把规约操作延迟到必要的时候才执行。

为了说明这些问题，先简要介绍一下OneFlow的SBP。

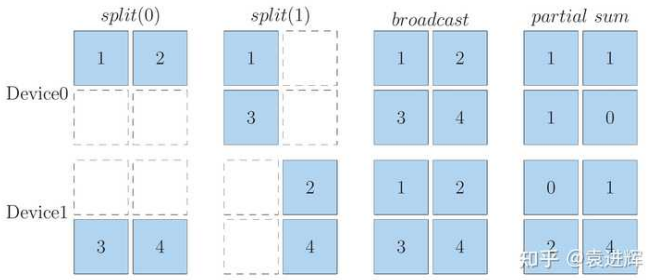

同样一个逻辑张量，在两个设备上可以有以上几种映射方式。

X	W	$Y = XW$
$S(0)$	B	$S(0)$
B	$S(1)$	$S(1)$
$S(1)$	$S(0)$	$P(sum)$
$P(sum)$	B	$P(sum)$
B	$P(sum)$	$P(sum)$
B	B	B

对于矩阵乘来说，当两个输入的SBP签名给定时，其输出的SBP签名也就确定了，上表罗列了所有合法的矩阵乘法的实现，从第5行和第6行可以看到，局部的结果可以作为矩阵乘的输入，只不过其输出也是局部结果罢了。假如有一连串的矩阵乘 Y = U * V * W，前面计算的局部计算结果是不需要在规约之后再参与下游的计算的，局部的计算结果可以一直在系统中流动，直到需要完整结果时才规约。

【补充一下，上文的partial 用unreduced 更精确一些。】

最后，**GShard对于多维划分的概念不够简洁**，对1维和多维使用了不同的定义，分别是split和shard，OneFlow统一使用split，只不过区分了是1D 还是ND， 更加通用。

下图展示了一个2维split的例子，设备被分成2个group，每个group里包含了2个device，一个矩阵可以首先通过S(0) 对0轴切分到两个group里面去，在每个group内部再可以通过S(1)按1轴划分，切分到2个device上去。

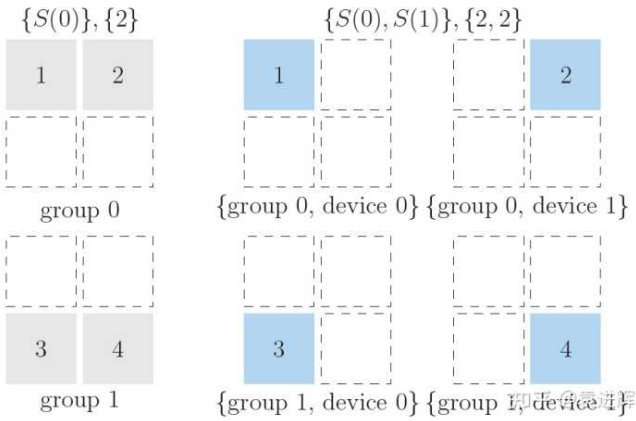

多维SBP可以有非常强大的功能，譬如基于SBP实现下面这篇文章描述的2D 矩阵乘就非常便利。

[An Efficient 2D Method for Training Super-Large Deep Learning Models (arxiv.org)]