

静态图流水并行功能增强和性 能优化

答辩人：郑天宇 / zty-king

指导人：陈锐彪 / From00

飞桨护航计划集训营





自我介绍：郑天宇

>>>>>>

我是电子科技大学计算机专业的研一学生，研究方向包括RAG、计算机视觉、强化学习。第七期黑客松护航计划结束后，我对飞桨平台有了深入了解，同时对模型分布式训练—流水并行方向产生了更强烈的兴趣，于是我继续参加了第八期黑客松护航计划。本次参与护航计划，我主要在流水并行功能增强和性能优化方向进行了大量的实践。





>>>>>>

PART1: 开发任务简介与个人拆解

PART2: 实际开发工作介绍

PART3: 未来工作规划

PART4: 总结与体会



PART1 : 开发任务简介与个人拆解

>>>>>>

任务1：自动并行下解决vpp策略通信死锁导致的hang问题

- vpp下拆解forward和backward，通过编排调度，解决生产环境下，vpp策略hang住的问题。

任务2：Locallayer API 优化


- 对标Locallayer，在此基础上优化，开发一个函数封装器local_map，函数经过封装后，允许用户将分布式张量传递给为普通张量编写的函数，使用户能够像编写单卡代码一样实现局部操作。
- 写了近10种单测示例验证动静半下local_map的正确性，同时替换Paddle，PaddleMIX和PaddleNLP中所有使用了LocalLayer的单测，并验证，同时修复一个存在潜在bug的单测

任务3：动态图的流水并行功能开发


- 协助开发动半下pp相关的数十个相关组件，根据开发的基本组件完善单测，测试并修复潜在的bug




PART2：实际开发工作介绍-vpp流水并行(背景介绍)




重切分阶段



编排阶段



Assign multiple stages to each device



Forward Pass Backward Pass



PART2：实际开发工作介绍-vpp下拆解forward和backward


>>>>>

问题分析



micro_batch_2做forward后，
send数据到GPU4
micro_batch_1做backward
后，也先做send，讲数据发
送到GPU3

此时，两个设备都在等待对
方做recv操作接收数据，陷
入通信死锁，导致hang



pp_degree=4,acc_step=8,vpp_degree=2



PART2：实际开发工作介绍-vpp下拆解forward和backward

>>>>>>>


方案设计

➤ 子图拆解：

- 将forward拆解为通信模块recv_forward和计算模块forward
- 将backward拆解为计算模块send_backward和通信模块send_backward。

➤ 编排改进：

- 编排阶段让forward先接收，backward再发送



子图拆解



编排改进



PART2：实际开发工作介绍-vpp下拆解forward和backward

>>>>>

实现效果

➤ 编排变化：

1. steady阶段编排变化：

从1F1B变为BrsF

(r表示recv_forward)

(s表示send_backward)

2. 计算 warm_up_steps的变化：

在上面公式基础上新增一条公式：

```
warm_up_steps = min(total_num_steps, warm_up_steps + 1)
```



拆解后，先接收再发送，不再陷入hang




PART2: 实际开发工作介绍-LocalLayer API 优化

>>>>>>>

背景介绍

- 在动半、静半分布式训练中，经常需要将分布式张量 (dist_tensor) 传递给为仅仅能处理普通张量 (dense_tensor) 或者必须以本地视角处理本地张量的函数。





PART2：实际开发工作介绍-LocalLayer API优化

>>>>>

问题分析

当前开发的Locallayer对于Layer含参数的情况，很难处理


```
# 创建 1D 的 ProcessMesh, 4 个设备
mesh = dist.ProcessMesh([0, 1, 2, 3], dim_names=['x'])

class MlpModel(dist.LocalLayer):
    def __init__(self):
        super(MlpModel, self).__init__()

        # w0 按列切分: Shard(1)
        self.w0 = dist.shard_tensor(
            self.create_parameter(shape=[1024, 4096]),
            mesh,
            [dist.Shard(1)])
        )

        # w1 按行切分: Shard(0)
        self.w1 = dist.shard_tensor(
            self.create_parameter(shape=[4096, 1024]),
            mesh,
            [dist.Shard(0)])
        )

    def forward(self, x):
        x = paddle.matmul(x, self.w0)
        z = paddle.matmul(x, self.w1)
        return z
```



- 这里存在两个问题：
1. LocalLayer 是本地视角的计算，此时 self.w 却带有分布式属性，违背了该 api 的设计原理
 2. 经过 LocalLayer 封装后，此时的计算不能使用框架的自动切分推导，即使计算也会出错

左侧示例的部分计算流程图




PART2：实际开发工作介绍-LocalLayer API优化

>>>>>

方案设计

- 以**函数形式**开发，而不再是**Layer****结构**。
- 添加**reshard**参数，由用户自由决定是否需要对输入的dtensor做**reshard**。
- 更改API命名为**local_map**与PyTorch对齐，便于用户迁移





PART2：实际开发工作介绍—LocalLayer API优化

>>>>>>

实现效果

| 方面 | LocalLayer | local_map |
|-----------|---|--|
| 封装方式 | 类封装，继承 Layer，重写 forward | 函数式包裹，接入即用 |
| 语法负担 | 必须定义类 + 结构复杂 | 一行代码即可创建分布式兼容函数 |
| 数据处理入口 | <code>__call__</code> 自动改写输入输出，可能会误用自身的参数 | 显式传参，灵活组合 |
| 状态管理 | 需要管理 Layer 状态 | 不存在状态概念 |
| reshard支持 | ✗ 无法做 reshards | ✓ 可以根据用户需求，批量对输入的 dtensor 做 reshards |
| 混合输出支持 | ✗ 只能输出 dtensor | ✓ 可以输出 dtensor、tensor，以及一些非 tensor 的数值 |

从“写个类、注册属性、重写forward”变成“包个函数、直接用”—
local_map 让并行封装像写普通函数一样简单。




PART2：实际开发工作介绍-动态图的流水并行功能开发

>>>>>>>

背景介绍

1. 当前仅在动手和静半两个场景下支持pp，
动半下没有pp相关组件，不支持pp。

2. 动手无法使用自动并行架构的一套自
动推导逻辑。






PART2：实际开发工作介绍-动态图的流水并行功能开发

>>>>>

动半PP开发工作概览

Lazy Initialization
添加单测





PART2：实际开发工作介绍-动态图的流水并行功能开发

>>>>>>>



PipelineStage设计：

用来构建流水并行过程一个 stage 的每个阶段。

开发目的：Schedule是基于

PipelineStage设计多种pp策

略的






PART2：实际开发工作介绍-动态图的流水并行功能开发

>>>>>

GET_PP_INFO_OF_LAYER组件：

为了让用户在使用pp策略时，
正确切分模型到对应的mesh上，
开发此工具。

将根据 hidden_layer_num,
mesh, pp_schedule, vpp_degree,
来处理模型切分，并根据
layer_index, 返回对应的mesh
信息，也可一次返回全部layer
的mesh信息。






PART2：实际开发工作介绍-动态图的流水并行功能开发

>>>>>>>


Schedules设计思路：

- 对于每个rank只分配一个stage的，我们开发组件 **PipelineScheduleSingle**，每个继承该类的pp策略重写 **step_microbatches**方法

- PipelineScheduleMulti**则实现了**step_microbatches**，继承该类的pp策略无需再写该方法。但需要初始化 **self.pipeline_order**，即每个rank执行的_Action列表，_Action.computation_type包含forward、backward、None等操作 (None表示当前时间步不做操作，即bubble)



PipelineScheduleSingle流程



设备中第一个块
设备中第二个块

None不做计算
但判断prev_rank_ops[time_step].computation_type为forward
则stage.get_fwd_recv_ops(mb_index)获取上一个stage forward输出数据

PipelineScheduleMulti的step_microbatches核心流程



PART2：实际开发工作介绍-动态图的流水并行功能开发

>>>>> Splitting Fronted(用户对模型做切分标记)

Schedules实现效果：

1. 该组件主要开发了三种pp策略：

single_stage: Gpipe、1F1B

multi_stage: VPP

2. 测试了三种策略；与同样数据和参数的动半朴素流水并行对齐了精度(数据采用float32, 对齐7位有效数字)；同时测试了dp、pp混合的case。

```
class PPMyModel_SingleStage(nn.Layer):
    def __init__(self):
        super().__init__()
        self.mesh=paddle.distributed.ProcessMesh([0,1,2,3], dim_names=["pp"])
        self.num_layers = 8
        self.num_layers_per_card = 2
        self.linears = nn.LayerList()
        for i in range(self.num_layers):
            linear = nn.Linear(8, 8, bias_attr=False)
            linear.weight = dist.shard_tensor(
                linear.weight,
                self.get_pp_mesh(i),
                [dist.Replicate()],
            )
            self.linears.append(linear)

    def get_pp_mesh(self, layer_index):
        # Layer_index=0-7 对应的 mesh_idx 分别为 0,0,1,1,2,2,3,3
        mesh_idx = int(layer_index // self.num_layers_per_card)
        return self.mesh[mesh_idx]

    def forward(self, x):
        x.stop_gradient = False
        out = x
        device_id = dist.get_rank()
        for i in range(self.num_layers):
            if int(i // self.num_layers_per_card) == device_id:
                out = self.linears[i](out)
        return paddle.cast(out, 'float32')
```

将layer给shard到不同的mesh上

不同rank执行其对应layer的forward

注意这里无需将out, shard到下一个pp_stage, 封装的组件会自动执行p2p通信

PipelineScheduleSingle

```
class PPMyModel_MultiStage(nn.Layer):
    def __init__(self):
        super().__init__()
        self.mesh=paddle.distributed.ProcessMesh([0,1,2,3], dim_names=["pp"])
        self.num_layers = 8
        self.linears = nn.LayerList()
        for i in range(self.num_layers):
            linear = nn.Linear(8, 8, bias_attr=False)
            linear.weight = dist.shard_tensor(
                linear.weight,
                self.get_pp_mesh(i),
                [dist.Replicate()],
            )
            self.linears.append(linear)

    def get_pp_mesh(self, layer_index):
        mesh_idx = int(layer_index % 4)
        return self.mesh[mesh_idx]

    def forward(self, x):
        # 对于MultiStage, 我们将模型层分片, 因此forward调用 Pipeline_model_chunk.forward
        pass

class Pipeline_model_chunk(nn.Layer):
    def __init__(self, layers):
        super(Pipeline_model_chunk, self).__init__()
        self.layers = layers
    def forward(self, x):
        out = x
        for layer in self.layers:
            out = layer(out)
        return out

def test_ScheduleInterleaved1F1B(self):
    fix_seeds()
    self.model = PPMyModel_MultiStage()
    self.local_stages=2
    self.micro_batches = 8
    self.stage_list=[]
    for i in range(self.local_stages):
        stage_model = Pipeline_model_chunk(self.model.linears[self.rank+i*4:self.rank+i*4+1])
        self.stage_list.append(PipelineStage(stage_model, self.rank+i*4, 8, group=self.group))
        self.stage_list[i].has_backward = True
```

vpp同样shard layer, 但注意layer分配方式不同

这里由于同一rank上的不同layer要处理不同的数据(因为是不同的stage), 因此用pipeline_model_chunk将不同chunk的层独立出来

PipelineScheduleMulti



PART3：未来工作规划

>>>>>>>

动态图的流水并行功能开发

- 动半pp的save-load场景存在精度不齐的问题，待修复
- 自动化Splitting Fronted，用户只需输入少量参数即可自动分割模型到不同设备上运行。(待定)
- Schedules组件的持续优化——如vpp适配更多非均衡情况、替换掉手动编排None的操作
- 继续开发动半pp的相关组件



PART4：总结与体会

>>>>>>>

护航计划成果总结

- 自动并行拆分vpp编排的forward和backward中的通信部分，修复生产下hang住的问题。
- 优化Locallayer，对标开发了local_map API。
- 协同开发动半pp相关的数十个组件，并编写大量单测

测试，理解组件设计逻辑，从而发现组件代码中的问题，

并进行bug修复


- 自我归纳总结出了dualpipe编排规律，并开发其编排代码。
- 记录20多页的dualpipe策略分析，以及10多页的locallayer动半，动手执行的日志分析。

DualPipe学习记录

Deepseek V3选择仍使用ZeRO-1

采用了16路流水并行和64路专家并行

1.Zero Bubble Pipeline Parallelism




这里B是做梯度计算，W是做梯度更新，往常来说，是所有backward做完，才一次性做所有的参数更新，分开后，即一个b一个w

动半，动手，加local_map的动手日志分析

1. 对比local_map下的动半和非local_map的动半（左是非法local_map动半（纯动半），右是local_map动半）

1.在进入loss函数计算之前，local_map下的动半和纯动半操作完全相同。

2.进入loss函数计算前，前面会多dtensor_to_local，动半是用dist_tensor在做loss计算，会自动推导进行shard，而local_map动半是使用dtensor_to_local，将其转化为dense_tensor去做



3.做loss函数中的绝对值计算的时候，动半看起来做了allgather？从shard分布，变成了replicated分布



4.绝对值计算后，后面的所有操作，动手用的是[32,1]的数据做的，且dims_mappings:[-1,-1]说明是全复制状态



PART4：总结与体会

>>>>>>

个人体会

- 流水并行策略的开发无法完全考虑到生产出现的每一个问题，但是要符合规范，并且要学会从问题中发现解决办法。
- API的设计与开发要足够合理化，不仅仅要以设计者的角度思考问题，更要考虑到用户实际使用过程中可能出现的潜在问题，并确保API接口对客户的使用体验友好。

Thanks ! Q&A

答辩人：郑天宇 / zty-king

指导人：陈锐彪 / From00

飞桨护航计划集训营

