

PR #6231 完整报告

verl-project/verl

[trainer] fix: update TorchTitanEngine for latest torchtitan API

合并时间: 2026-05-06 17:38

原文链接: <http://prhub.com.cn/verl-project/verl/pull/6231>

执行摘要

- 一句话: 修复 TorchTitanEngine 适配最新 torchtitan API
- 推荐动作: 建议合并, 这是一个兼容性和 bug 修复 PR, 解决已知问题并跟上上游变化。团队可以关注 torchtitan 的稳定性, 未来考虑锁定依赖版本。

功能与动机

torchtitan 上游 API 发生了 breaking change, 如 `expert_tensor_parallel_degree` 被删除、`model_registry` 新增 `attn_backend` 参数等, 导致 TorchTitanEngine 无法正常工作。Issue #6182 报告了 `attn_type="flex"` 被静默忽略的问题, 根本原因是 `model_registry` 调用时未传递 `attn_backend`。

实现拆解

1. 调整 `parallelism` 配置: 删除 `expert_tensor_parallel_degree` (已在 torchtitan 上游移除) 和 `etp` 参数。
2. 修复 `attn_type` 传递: 在 `model_registry()` 调用中传入 `attn_backend=self.engine_config.attn_type`, 替换之前的手动覆写 `model_spec.model.layer.attention.attn_backend` 的逻辑。
3. 修复 `get_attention_masks` 调用: 将 `attn_type` 的读取路径从 `self.trainer.model_config.layer.attention.attn_backend` 修正为 `self.engine_config.attn_type`, 解决属性不存在的问题。
4. 新增损失函数配置: 导入 `CrossEntropyLoss.Config` 并添加到 Trainer 配置中, 因为 torchtitan 的 Trainer 现在需要显式提供损失函数配置。
5. 重构 flavor 推导逻辑: 在 `utils.py` 中, 使用 `model_registry(flavor_name).model` 获取模型配置, 并支持 `n_layers` 回退到 `len(layers)`, 以兼容不同配置格式。
6. 修复测试脚本: 在 `tests/special_e2e/run_ppo_trainer_torchtitan.sh` 中, 将硬编码的 TP 大小 8 改为 `NUM_GPUS` 变量, 并修正实验名称。

关键文件:

- `verl/workers/engine/torchtitan/transformer_impl.py` (模块引擎; 类别 source; 类型 dependency-wiring; 符号 TorchTitanEngine): 核心引擎文件, 修复了 `attn_backend` 传递、删除已弃用参数、添加 `CrossEntropyLoss` 配置等关键变更。

- verl/workers/engine/torchtitan/utils.py (模块 工具; 类别 source; 类型 core-logic; 符号 derive_torchtitan_name_and_flavor) : 重构了 derive_torchtitan_name_and_flavor 函数, 使用 model_registry 并支持 n_layers 回退到 len(layers)。

关键符号: derive_torchtitan_name_and_flavor, TorchtitanEngine.init, TorchtitanEngine.model_forward_step, TorchtitanEngine.prepare_model_inputs, TorchtitanEngine._init_device_mesh

关键源码片段

verl/workers/engine/torchtitan/transformer_impl.py

核心引擎文件, 修复了 attn_backend 传递、删除已弃用参数、添加 CrossEntropyLoss 配置等关键变更。

```
# ... 在 __init__ 方法中
# 使用 model_registry 并传递 attn_backend 参数
model_spec = model_module.model_registry(
    torchtitan_flavor,
    attn_backend=self.engine_config.attn_type
)

# 注意: 不再需要手动覆写 attn_backend, 因为 torchtitan 现在负责处理

# 配置 ParallelismConfig 时删除已弃用的 expert_tensor_parallel_degree
parallelism = ParallelismConfig(
    data_parallel_replicate_degree=self.engine_config.data_parallel_replicate_size,
    data_parallel_shard_degree=self.engine_config.data_parallel_shard_size,
    fsdp_reshard_ratio=self.engine_config.fsdp_reshard_ratio,
    tensor_parallel_degree=self.engine_config.tensor_parallel_size,
    pipeline_parallel_degree=self.engine_config.pipeline_parallel_size,
    context_parallel_degree=self.engine_config.context_parallel_size,
    expert_parallel_degree=self.engine_config.expert_parallel_size,
    # expert_tensor_parallel_degree 已在 torchtitan 中移除
)

# 添加 CrossEntropyLoss.Config, 因为 Trainer 需要显式损失配置
training = TrainingConfig(
    batch_size=self.engine_config.training_batch_size,
    num_steps=self.optimizer_config.total_training_steps,
    compile=CompileConfig(),
    loss=CrossEntropyLoss.Config(), # verl 使用自己的损失函数, 此仅为占位
)
```

verl/workers/engine/torchtitan/utils.py

重构了 derive_torchtitan_name_and_flavor 函数, 使用 model_registry 并支持 n_layers 回退到 len(layers)。

```
def derive_torchtitan_name_and_flavor(hf_config) -> tuple[str, str]:
    # ... 获取 model_type 和 name ...
```

```

model_module = importlib.import_module(f"torch titan.models.{name}")
model_registry = model_module.model_registry

# 通过遍历模块变量找到 flavor 名称列表
flavor_names = None
for attr, obj in vars(model_module).items():
    if attr.endswith("_configs") and isinstance(obj, dict):
        flavor_names = list(obj.keys())
        break

if flavor_names is None:
    raise ValueError(...)

hidden_size = hf_config.hidden_size
num_layers = hf_config.num_hidden_layers
vocab_size = hf_config.vocab_size

for flavor_name in flavor_names:
    cfg = model_registry(flavor_name).model # 使用 model_registry 构建配置
    n_layers = getattr(cfg, "n_layers", None) or len(getattr(cfg, "layers", [])) # 支持 layers 回退
    if (
        getattr(cfg, "dim", None) == hidden_size
        and n_layers == num_layers
        and getattr(cfg, "vocab_size", None) == vocab_size
    ):
        return name, flavor_name

raise ValueError(f"No match for {hidden_size}, {num_layers}, {vocab_size}")

```

评论区精华

无 review 评论，PR 由 wuxibin89 直接批准合并。

- 暂无高价值评论线程

风险与影响

- 风险：主要风险在于 torch titan 上游 API 仍然不稳定，未来可能再次发生 breaking change，需要持续跟踪。同时，本次改动删除了一些参数（如 etp），如果用户配置中依赖这些参数，可能导致配置错误。但该模块仍属于 experimental 阶段，风险可控。
- 影响：影响范围为使用 TorchTitanEngine 的训练任务。修复了 attn_type 被忽略的严重 bug，并确保了与最新 torch titan 版本的兼容性。用户需要更新 torch titan 到对应 HEAD 版本才能配合使用。
- 风险标记：上游 API 不稳定，实验性模块，无测试配套

关联脉络

- PR #6182 [trainer] bug: TorchTitanEngine silently ignores attn_type="flex" — no clear BKM for which torchtitan version to use: 该 issue 报告了 attn_type 被忽略的 bug, 本 PR 是其修复。