

PR #36883 完整报告

sgl-project/sglang

[Diffusion] Resolve indexed component weight sets

合并时间: 2026-08-29 14:21

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/36883>

执行摘要

- 一句话: 新增索引式组件权重集解析, 重构 transformer 覆盖加载
- 推荐动作: 值得精读。重点看 `weights/source.py` 中 `index` 权威解析与错误类型区分的设计, 以及 `transformer_load_utils.py` 如何从自维护下载逻辑收敛到共享解析器; 这套解析器可视为给其他组件加权重覆盖的现成模板。

功能与动机

PR body 将其定位为“shared checkpoint infrastructure for pipeline-declared components”: 需要一个模型无关的组件权重集解析器, 统一处理本地路径、HF repo、子文件夹、精确文件和标准 safetensors indexes, 并“treat the index as shard authority, reject ambiguous unindexed variants”, 同时把权重与相邻量化元数据固定到同一不可变 Hub revision, 避免加载到混搭的不同 checkpoint 版本。历史 PR #22360 曾因重复加载 transformer safetensors 变体引入防御测试, 本 PR 正是从解析层根治该问题。

实现拆解

1. 权重源层新增索引解析 (`python/sglang/multimodal_gen/runtime/weights/source.py`, +236/-13): 新增 `_SAFETENSORS_INDEX_SUFFIX` 与 `_WEIGHT_REFERENCE_SUFFIXES` 常量, 使 `.safetensors.index.json` 也能作为显式权重引用; 新增 `ResolvedWeightSet` (选中文件元组 + 权威 index 文件名) 与 `NoSafetensorsWeightsError` 异常; `_local_index_inventory` 只按 index 的 `weight_map` 收集本地分片; `resolve_safetensors_weight_set / materialize_weight_set` 及私有辅助 `_read_safetensors_index`、`_resolve_index_shard`、`_materialize_inventory_file` 完成索引解析与物化, 无索引歧义目录抛 `ValueError`, 无 safetensors 载荷抛专有异常。
2. transformer 覆盖加载收敛到共享解析器 (`python/sglang/multimodal_gen/runtime/loader/transformer_load_utils.py`, +54/-101): 删除 `_HF_SAFETENSORS_URL_RE` 正则以及直接调用 `hf_hub_download`、`maybe_download_model`、`snapshot_download` 的分支; `resolve_transformer_safetensors_to_load` 重构为 `resolve_transformer_checkpoint_files`, 返回新增的 `TransformerCheckpointFiles` (`safetensors` 元组 + `config_path`), 覆盖路径全部委托给 `resolve_safetensors_weight_set`, 同时保留 `_select_single_mixed_safetensors_file` 作为既有 `*-mixed.safetensors` 单文件兼容路径。

3. 加载器接入 (`python/sglang/multimodal_gen/runtime/loader/component_loaders/transformer_loader.py`, +6/-2) : `load_customized` 改用 `resolve_transformer_checkpoint_files`, 并把 `checkpoint_files.config_path` 传入 `TransformerQuantLoadSpec` 的新字段 `transformer_override_config_path`; GGUF 分支保持原样 (`safetensors_list = []`) 。
4. 测试配套: `test_weight_source.py` 新增 8 个用例, 覆盖 index 只选声明 shard、精确 index 解析相邻 shard、拒绝无索引变体、拒绝非权重 shard、缺失 shard 不算“无权重”、远端多 shard 固定单一 revision 等; `test_transformer_quant.py` 把 mock 目标从 `transformer_load_utils.hf_hub_download` 迁移到 `weights.source.HfApi.model_info / hf_hub_download`, 并验证单文件覆盖、HF revision 固定与 mixed 兼容路径。

关键文件:

- `python/sglang/multimodal_gen/runtime/weights/source.py` (模块 权重解析; 类别 source; 类型 core-logic; 符号 `ResolvedWeightSet`, `NoSafetensorsWeightsError`, `_local_index_inventory`, `materialize_weight`) : 新增 `ResolvedWeightSet`, `NoSafetensorsWeightsError` 与 `resolve_safetensors_weight_set` 等索引权重集解析核心, 是本次变更的主实现。
- `python/sglang/multimodal_gen/runtime/loader/transformer_load_utils.py` (模块 加载逻辑; 类别 source; 类型 refactor; 符号 `TransformerCheckpointFiles`, `resolve_transformer_safetensors_to_load`, `resolve_transformer_checkpoint_files`, `_select_single_mixed_safetensors_file`) : 将 transformer 权重覆盖从自维护的 HF 下载 / 正则分支迁移到共享解析器, 新增 `TransformerCheckpointFiles` 返回结构, 删除约 100 行重复逻辑。
- `python/sglang/multimodal_gen/runtime/loader/component_loaders/transformer_loader.py` (模块 加载器; 类别 source; 类型 core-logic) : 接入新解析结果, 并把 `transformer_override_config_path` 传进量化 spec, 是行为落地点。
- `python/sglang/multimodal_gen/test/unit/test_weight_source.py` (模块 单元测试; 类别 test; 类型 test-coverage; 符号 `test_safetensors_index_selects_only_declared_shards`, `test_exact_local_safetensors_index_resolves_adjacent_shards`, `test_safetensors_weight_set_rejects_unindexed_variants`, `test_safetensors_index_rejects_non_weight_shard`) : 新增 8 个用例覆盖 index 解析、拒绝非权重 shard、无索引变体、远端单 revision 固定等核心行为。
- `python/sglang/multimodal_gen/test/unit/test_transformer_quant.py` (模块 单元测试; 类别 test; 类型 test-coverage; 符号 `test_resolve_transformer_safetensors_to_load_use_s_single_override_file`, `test_resolve_transformer_checkpoint_files_uses_single_override_file`, `test_resolve_transformer_safetensors_to_load_uses_hf_file_reference`, `test_resolve_transformer_checkpoint_files_uses_one_hf_revision`) : 测试随重构迁移 mock 位置, 验证单文件覆盖、HF 单 revision 与 mixed 兼容路径。

关键符号: `resolve_safetensors_weight_set`, `materialize_weight_set`, `materialize_weight_set_config`, `_local_index_inventory`, `_resolve_index_shard`, `_read_safetensors_index`, `resolve_transformer_checkpoint_files`, `_select_single_mixed_safetensors_file`, `materialize_weight`

关键源码片段

[python/sglang/multimodal_gen/runtime/weights/source.py](#)

新增 ResolvedWeightSet、NoSafetensorsWeightsError 与 resolve_safetensors_weight_set 等索引权重集解析核心，是本次变更的主实现。

```
# python/sglang/multimodal_gen/runtime/weights/source.py
# 权重集解析核心：新增常量、数据结构和 index 解析辅助函数

_SAFETENSORS_INDEX_SUFFIX = ".safetensors.index.json"
_WEIGHT_REFERENCE_SUFFIXES = _WEIGHT_SUFFIXES + (_SAFETENSORS_INDEX_SUFFIX,)
```

```
@dataclass(frozen=True)
class ResolvedWeightSet:
    """一次解析得到的权重集：同一 checkpoint revision 下的一组文件。
```

与 ResolvedWeight 不同，它承载多个 safetensors 文件（分片），并保留权威 index 文件名供日志与排障使用。

```
    """
    inventory: WeightInventory
    selected_files: tuple[str, ...]
    index_file: str | None = None
```

```
class NoSafetensorsWeightsError(FileNotFoundError):
    """源中没有 safetensors 载荷可解析为权重集。
```

和普通 FileNotFoundError 区分开，让上层能识别“没有权重”而不是“路径写错”。

```
def _local_index_inventory(index_path: Path) -> tuple[str, ...]:
    """只列出精确的本地 index 及其声明、且物理存在的分片。

    目录里可能还有别的 safetensors 变体（如 distilled/base），
    但这里严格以 index 的 weight_map 为权威，避免歧义加载。
    """
    with index_path.open(encoding="utf-8") as index_stream:
        index = json.load(index_stream)
    weight_map = index.get("weight_map") if isinstance(index, Mapping) else None
    shard_names = weight_map.values() if isinstance(weight_map, Mapping) else ()
    files = {index_path.name}
    for shard_name in shard_names:
        # 校验 shard 相对路径是否合法，避免目录穿越
        if not isinstance(shard_name, str):
            continue
        shard_name = _validate_relative_hub_path(shard_name, "index shard")
```

```

shard_path = index_path.parent / shard_name
if shard_path.is_file():
    files.add(shard_path.relative_to(index_path.parent).as_posix())
return tuple(sorted(files))

```

python/sglang/multimodal_gen/runtime/loader/transformer_load_utils.py

将 transformer 权重覆盖从自维护的 HF 下载 / 正则分支迁移到共享解析器，新增 TransformerCheckpointFiles 返回结构，删除约 100 行重复逻辑。

```

# python/sglang/multimodal_gen/runtime/loader/transformer_load_utils.py
# transformer 覆盖加载统一走共享权重集解析器

```

```

@dataclass(frozen=True)
class TransformerCheckpointFiles:
    """transformer 加载所需文件：safetensors 列表 + 相邻 config.json。"""
    safetensors: tuple[str, ...]
    config_path: str | None

```

```

def resolve_transformer_checkpoint_files(
    server_args: ServerArgs, component_model_path: str
) -> TransformerCheckpointFiles:
    """从基础组件路径或量化覆盖路径解析 transformer 权重文件。

```

有覆盖时统一委托给 resolve_safetensors_weight_set，覆盖源可以是本地目录、Hugging Face repo、子文件夹、精确文件或 safetensors index；解析出的 config.json 会作为配置路径带出。无覆盖时回退到基础组件路径，并保留 *-mixed.safetensors 单文件兼容选择。

```

"""
quantized_path = server_args.transformer_weights_path
if quantized_path:
    resolved = resolve_safetensors_weight_set(quantized_path)
    safetensors = tuple(materialize_weight_set(resolved))
    config_path = next(
        (path for path in resolved.inventory.files
         if path.endswith("config.json")),
        None,
    )
    return TransformerCheckpointFiles(
        safetensors=safetensors, config_path=config_path
    )
# 基础组件路径：沿用原有探测逻辑，优先单一 mixed 导出
selected = _select_single_mixed_safetensors_file(component_model_path)
return TransformerCheckpointFiles(safetensors=selected, config_path=None)

```

评论区精华

PR 没有 review 评论，唯一讨论是作者 mickqian 在 issue 评论中的说明：重构把 checkpoint 物化移入通用 weight-source resolver 后，测试仍 patch 了已删除的私有导入 `transformer_load_utils.maybe_download_model`，导致 NVIDIA 单元测试失败。修复后，Nunchaku 测试保持聚焦量化 hook 解析，本地文件 resolver 测试验证既不调用 Hub 元数据也不调用下载 API，且没有新增任何运行时行为或兼容 shim。

- CI 失败：测试仍 patch 已删除的 `maybe_download_model` (testing): 测试改为 patch `weights.source.HfApi.model_info` 与 `hf_hub_download`，Nunchaku 测试保持专注 quant hook 解析，本地文件 resolver 测试验证不触发 Hub 元数据或下载 API。

风险与影响

- 风险：
 1. 行为变更：`resolve_safetensors_weight_set` 会拒绝没有 index 的 safetensors 目录（报错信息含“without an index”），原来依赖目录自动探测的用户配置可能报错。
 2. 下载逻辑集中化：transformer 覆盖中所有 HF URL 处理移入 `weights/source.py`，若存在未被 `parse_weight_source` 覆盖的 URL 形态，可能出现回归。
 3. 配置键调整：TransformerQuantLoadSpec 新增 `transformer_override_config_path` 字段，需要确认所有构造点已同步更新。
 4. CI 信号：Extra 与 AMD ROCm 跑失败过，NVIDIA 修复后已重跑，仍提示跨平台回归风险。
 5. 兼容性保护：`*-mixed.safetensors` 单文件路径与 GGUF 行为保持不变，风险总体可控。
 - 影响：变更影响 `sglang diffusion` 运行时中 transformer 组件的权重覆盖加载路径，并为其建立共享基础设施。用户现在可以用 safetensors index 声明分片权重集，也可以继续使用单一 `*-mixed.safetensors`；GGUF 与基础组件加载不受影响。对团队而言，`weights/source.py` 成为各组件加载器的统一入口，后续新增组件权重覆盖可直接复用这套解析逻辑。
 - 风险标记：无 index 权重目录将报错（行为变更），HF 下载逻辑集中迁移，CI Extra/AMD 曾失败，量化覆盖配置键调整

关联脉络

- PR #36902 [Diffusion] Delegate recognized quantized components to Transformers: 同属 diffusion 组件加载与量化覆盖功能线，本 PR 将 transformer 覆盖解析交给共享 weight-source resolver，与组件委托加载形成配套。
- PR #36874 [Diffusion] Respect component weight overrides for upsamplers: 同一“组件权重覆盖”功能线，本 PR 为覆盖提供更通用的权重集解析基础。
- PR #36863 [Diffusion] Fix image encoder parallel folding proposal: 与 `server_args/` 组件配置解析同区，可作为本次重构后的回归观察对象。