

PR #27313 完整报告

sgl-project/sglang

[2/n] [CP] Add context parallel strategy abstractions

合并时间: 2026-06-16 15:20

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/27313>

执行摘要

- 一句话: 新增上下文并行策略抽象层
- 推荐动作: 值得精读, 尤其是 ContextParallelStrategy 抽象基类和包组织结构。该设计为后续模型无关的 CP 分片打下基础, 是 CP 重构的核心抽象。关注后续的 #27314 等 PR 以了解逐步填充的实现。

功能与动机

现有 Context Parallelism (CP) 的实现分散在模型文件和注意力后端中, server args 混乱、模型覆盖率不对称、通信代码散落。为系统化重构, 需要引入 strategy-owned runtime abstraction, 将 CP 分片逻辑统一到策略接口中。详见 Roadmap Issue #27252。

实现拆解

1. 创建 CP 包和核心抽象: 在 `python/sglang/srt/layers/cp/` 下创建包, `base.py` 定义 `ContextParallelStrategyKind` 枚举 (NONE/ZIGZAG/INTERLEAVE)、`CpAttentionBackendKind` 枚举、`BaseContextParallelMetadata` 数据类, 以及 `ContextParallelStrategy` 抽象基类, 声明 `can_apply`、`build_metadata`、`shard_hidden_states`、`shard_position_ids`、`gather_hidden_states`、`gather_kv_cache` 等抽象方法。
2. 实现策略 Shell: `zigzag.py` 实现 `ZigzagCPStrategy`, `interleave.py` 实现 `InterleaveCPStrategy`。当前仅实现 `can_apply` (检查 `cp_size` 和 `token` 数) 和 `build_metadata` (返回基本元数据), 其余方法 `raise NotImplementedError`, 留待后续 PR。
3. 环境变量门控: 在 `environ.py` 中添加 `SGLANG_ENABLE_CP_V2` (默认 `False`), 并保留别名 `SGLANG_ENABLE_REFACTOR_CP` 作为兼容。新增 `use_cp_v2()` 函数 (后因 review 删除, 改用 `is_cp_enabled` 替代)。
4. 集成 server args: 在 `server_args.py` 的 `_handle_context_parallelism` 方法末尾调用 `init_cp_strategy(self)`, 从规范化后的 server args 初始化策略单例。同时添加 `cp_strategy` 字段映射和验证。
5. 公共导出与门面: 在 `__init__.py` 和 `utils.py` 中集中导出所有公共符号, 提供 `is_cp_enabled`、`is_zigzag`、`is_interleave`、`get_cp_strategy`、`get_cp_strategy_kind` 等便捷函数。

6. 测试覆盖：新增 `test/registered/cp/test_cp_strategy_unit.py`，测试枚举解析、策略初始化、门控 `SGLANG_ENABLE_CP_V2` 兼容性；扩展 `test_server_args.py` 验证 context parallel handler 会初始化策略。

关键文件：

- `python/sglang/srt/layers/cp/base.py`（模块 CP 抽象层；类别 source；类型 dependency-wiring；符号 `ContextParallelStrategyKind`, `from_string`, `cli_value`, `CPAttentionBackendKind`）：核心文件，定义策略枚举、注意力后端枚举、基础元数据类型和 `ContextParallelStrategy` 抽象基类，包含所有抽象方法签名和进程级单例辅助函数。
- `python/sglang/srt/layers/cp/zigzag.py`（模块 CP 抽象层；类别 source；类型 dependency-wiring；符号 `ZigzagContextParallelMetadata`, `ZigzagCPStrategy`, `can_apply`, `build_metadata`）：`Zigzag` 策略的具体实现壳，包括 `ZigzagContextParallelMetadata` 数据类和 `ZigzagCPStrategy` 类，展示策略接口的初步填充。
- `python/sglang/srt/layers/cp/interleave.py`（模块 CP 抽象层；类别 source；类型 dependency-wiring；符号 `InterleaveContextParallelMetadata`, `InterleaveCPStrategy`, `can_apply`, `build_metadata`）：`Interleave` 策略的具体实现壳，结构类似 `zigzag.py`，展示另一策略的骨架。
- `python/sglang/srt/layers/cp/utils.py`（模块 CP 抽象层；类别 source；类型 dependency-wiring）：公共导入门面，导出所有关键类型和辅助函数，便于外部模块引用。
- `python/sglang/srt/layers/cp/__init__.py`（模块 CP 抽象层；类别 source；类型 dependency-wiring）：包初始化文件，确保从 `sglang.srt.layers.cp` 直接导入主要符号。
- `python/sglang/srt/envron.py`（模块 环境配置；类别 source；类型 core-logic）：添加 `SGLANG_ENABLE_CP_V2` 环境变量门控，控制是否启用新的 CP v2 策略路由。
- `python/sglang/srt/server_args.py`（模块 服务配置；类别 source；类型 dependency-wiring）：在 `_handle_context_parallelism` 中调用 `init_cp_strategy`，确保服务器启动时根据规范化的参数初始化策略单例。
- `test/registered/cp/test_cp_strategy_unit.py`（模块 单元测试；类别 test；类型 test-coverage；符号 `TestCPStrategyUnit`, `tearDown`, `test_strategy_kind_maps_cli_values`, `test_init_cp_strategy_binds_zigzag_strategy`）：单元测试文件，验证枚举解析、策略初始化、门控环境变量兼容性，保证基础功能正确。
- `test/registered/unit/server_args/test_server_args.py`（模块 服务配置；类别 test；类型 test-coverage；符号 `test_context_parallel_handler_initializes_cp_strategy`）：扩展现有 `server args` 测试，验证 context parallel handler 会调用 `init_cp_strategy`。

关键符号：`ContextParallelStrategyKind.from_string`,

`ContextParallelStrategyKind.cli_value`, `CPAttentionBackendKind.from_string`,

`ContextParallelStrategy.init`, `ContextParallelStrategy.cp_rank`,

`ContextParallelStrategy.can_apply`, `ContextParallelStrategy.build_metadata`,

`ContextParallelStrategy.shard_hidden_states`,

`ContextParallelStrategy.shard_position_ids`, `ContextParallelStrategy.gather_hidden_states`, `ContextParallelStrategy.gather_kv_cache`, `ZigzagCPStrategy.can_apply`,

`ZigzagCPStrategy.build_metadata`, `InterleaveCPStrategy.can_apply`,

InterleaveCPStrategy.build_metadata, init_cp_strategy, get_cp_strategy,
get_cp_strategy_kind, is_cp_enabled, is_zigzag, is_interleave,
TestCPStrategyUnit.test_strategy_kind_maps_cli_values,
TestCPStrategyUnit.test_init_cp_strategy_binds_zigzag_strategy,
TestCPStrategyUnit.test_get_cp_strategy_is_initialized_under_cp_v1_and_cp_v2

关键源码片段

python/sclang/srt/layers/cp/zigzag.py

Zigzag 策略的具体实现壳，包括 ZigzagContextParallelMetadata 数据类和 ZigzagCPStrategy 类，展示策略接口的初步填充。

(ZigzagCPStrategy 部分实现)

```
class ZigzagCPStrategy(ContextParallelStrategy):
```

```
    name = "zigzag"
```

```
    kind = ContextParallelStrategyKind.ZIGZAG
```

```
def can_apply(self, num_tokens: int, forward_batch) -> bool:
```

```
    # 要求 cp_size > 1 且 token 数至少为 2 * cp_size
```

```
    if self.cp_size <= 1 or num_tokens < self.cp_size * 2:
```

```
        return False
```

```
    forward_mode = getattr(forward_batch, "forward_mode", None)
```

```
    # 仅允许在 context parallel extend 模式下应用
```

```
    return forward_mode is None or forward_mode.is_context_parallel_extend()
```

```
def build_metadata(
```

```
    self,
```

```
    num_tokens: int,
```

```
    seqs_len: Optional[List[int]],
```

```
    extend_seqs_len: Optional[List[int]] = None,
```

```
) -> ZigzagContextParallelMetadata:
```

```
    # 构建基础的元数据，后续 PR 会填充详细的分拆信息
```

```
    return ZigzagContextParallelMetadata(
```

```
        total_seq_lens=sum(extend_seqs_len or seqs_len or [num_tokens]),
```

```
        bs=len(extend_seqs_len or seqs_len or [num_tokens]),
```

```
    )
```

```
# 以下方法留待后续 PR 实现
```

```
def shard_hidden_states(self, x: Any, forward_batch) -> Any:
```

```
    raise NotImplementedError("Zigzag hidden-state sharding will land in a follow-up PR")
```

```
def shard_position_ids(self, positions: Any, forward_batch) -> Any:
```

```
    raise NotImplementedError("Zigzag position-id sharding will land in a follow-up PR")
```

```
def gather_hidden_states(self, x: Any, forward_batch, stream: Optional[Any] = None) -> Any:
```

```
    raise NotImplementedError("Zigzag hidden-state gather will land in a follow-up PR")
```

```
def gather_kv_cache(self, x: Any, forward_batch, stream: Optional[Any] = None) -> Any:
```

```
raise NotImplementedError("Zigzag KV gather will land in a follow-up PR")
```

```
def run_attention(self, q: Any, forward_batch, device: Any, attn_fn,  
    attention_backend: CPAttentionBackendKind = CPAttentionBackendKind.FLASH_  
    ATTENTION) -> Any:  
    raise NotImplementedError("Zigzag attention dispatch will land in a follow-up PR")
```

python/sglang/srt/layers/cp/interleave.py

Interleave 策略的具体实现壳，结构类似 zigzag.py，展示另一策略的骨架。

```
# (InterleaveCPStrategy 部分实现 )  
class InterleaveCPStrategy(ContextParallelStrategy):  
    name = "interleave"  
    kind = ContextParallelStrategyKind.INTERLEAVE  
  
    def can_apply(self, num_tokens: int, forward_batch) -> bool:  
        # 要求 cp_size > 1 且 token 数至少为 cp_size  
        if self.cp_size <= 1 or num_tokens < self.cp_size:  
            return False  
        forward_mode = getattr(forward_batch, "forward_mode", None)  
        return forward_mode is None or forward_mode.is_context_parallel_extend()  
  
    def build_metadata(  
        self,  
        num_tokens: int,  
        seqs_len: Optional[List[int]],  
        extend_seqs_len: Optional[List[int]] = None,  
    ) -> InterleaveContextParallelMetadata:  
        return InterleaveContextParallelMetadata(  
            total_seq_lens=sum(extend_seqs_len or seqs_len or [num_tokens]),  
            bs=len(extend_seqs_len or seqs_len or [num_tokens]),  
        )  
  
    # 以下方法留待后续 PR 实现  
    def shard_hidden_states(self, x: Any, forward_batch) -> Any:  
        raise NotImplementedError("Interleave hidden-state sharding will land in a follow-up PR")  
  
    def shard_position_ids(self, positions: Any, forward_batch) -> Any:  
        raise NotImplementedError("Interleave position-id sharding will land in a follow-up PR")  
  
    def gather_hidden_states(self, x: Any, forward_batch, stream: Optional[Any] = None) -> Any:  
        raise NotImplementedError("Interleave hidden-state gather will land in a follow-up PR")  
  
    def gather_kv_cache(self, x: Any, forward_batch, stream: Optional[Any] = None) -> Any:  
        raise NotImplementedError("Interleave KV gather will land in a follow-up PR")
```

test/registered/cp/test_cp_strategy_unit.py

单元测试文件，验证枚举解析、策略初始化、门控环境变量兼容性，保证基础功能正确。

```

import unittest
from types import SimpleNamespace
from unittest.mock import patch

from sglang.srt.layers.cp.base import (
    ContextParallelStrategyKind,
    get_cp_strategy,
    get_cp_strategy_kind,
    init_cp_strategy,
    is_cp_enabled,
    is_interleave,
    is_zigzag,
)
from sglang.test.ci.ci_register import register_cpu_ci
from sglang.test.test_utils import CustomTestCase

register_cpu_ci(est_time=2, suite="base-a-test-cpu")

class TestCPStrategyUnit(CustomTestCase):
    def tearDown(self):
        # 每次测试后关闭 CP，避免影响其他测试
        init_cp_strategy(SimpleNamespace(enable_prefill_cp=False))

    def test_strategy_kind_maps_cli_values(self):
        # 验证枚举值与 CLI 字符串的映射
        self.assertEqual(ContextParallelStrategyKind.NONE.value, 0)
        self.assertEqual(
            ContextParallelStrategyKind.from_string("zigzag"),
            ContextParallelStrategyKind.ZIGZAG,
        )
        self.assertEqual(
            ContextParallelStrategyKind.from_string("interleave"),
            ContextParallelStrategyKind.INTERLEAVE,
        )
        self.assertEqual(ContextParallelStrategyKind.ZIGZAG.cli_value, "zigzag")
        self.assertEqual(ContextParallelStrategyKind.INTERLEAVE.cli_value, "interleave")

    def test_init_cp_strategy_binds_zigzag_strategy(self):
        # 模拟启用 CP 并选用 zigzag 策略，验证单例状态
        init_cp_strategy(
            SimpleNamespace(
                enable_prefill_cp=True,
                cp_strategy="zigzag",
                attn_cp_size=4,
            )
        )
        self.assertTrue(is_cp_enabled())
        self.assertTrue(is_zigzag())

```

```

self.assertFalse(is_interleave())
self.assertEqual(get_cp_strategy_kind(), ContextParallelStrategyKind.ZIGZAG)

def test_get_cp_strategy_is_initialized_under_cp_v1_and_cp_v2(self):
    # 验证在 CP v1 (SGLANG_ENABLE_CP_V2=False) 和 CP v2 下策略均被初始化
    init_cp_strategy(
        SimpleNamespace(
            enable_prefill_cp=True,
            cp_strategy="interleave",
            attn_cp_size=4,
        )
    )
    with patch(
        "sglang.srt.environ.envs.SGLANG_ENABLE_CP_V2.get", return_value=False
    ):
        self.assertIsNotNone(get_cp_strategy())
        self.assertTrue(is_cp_enabled())
        self.assertTrue(is_interleave())

    with patch(
        "sglang.srt.environ.envs.SGLANG_ENABLE_CP_V2.get", return_value=True
    ):
        self.assertIsNotNone(get_cp_strategy())

if __name__ == "__main__":
    unittest.main()

```

评论区精华

文件命名与组织：作者将 `strategy.py` 重命名为 `utils.py`，并将初始化逻辑、`use_cp_v2` 等函数移入 `base.py`，简化文件结构。同时明确了 `shard_hidden_states/gather_hidden_states` 等方法的命名和职责（在 `base.py` 中关联评论）。

CP v2 门控简化：最初 `use_cp_v2()` 函数被提出，但经 review 认为可直接通过 `is_cp_enabled()` 覆盖，故移除。`SGLANG_ENABLE_CP_V2` 改为直接使用 `EnvBool` 而非 `EnvBoolWithAlias`。

添加策略说明图：要求在 `zigzag.py` 和 `interleave.py` 文件头部添加 ASCII 图表说明分片方式，从旧 `cp_utils.py` 迁移。

测试适应性：测试中确保 `get_cp_strategy()` 在 CP v1 和 CP v2 下均返回非 None，且 `init_cp_strategy` 在两种情况下均被调用。

- 文件命名与组织 (design): 已执行：文件重命名、函数移动、copyright 更新。
- CP v2 门控简化 (design): 已移除 `use_cp_v2`，改用 `is_cp_enabled`；环境变量改为 `EnvBool`。
- 添加策略说明 ASCII 图 (documentation): 已添加图表说明，用户可直观了解分片方案。
- 抽象方法命名与职责明确 (design): 已按建议重命名并更新 docstring。

- 测试覆盖门控分支 (testing): 测试已补充 `test_get_cp_strategy_is_initialized_under_cp_v1_and_cp_v2`, 使用 `patch` 模拟环境变量。

风险与影响

- 风险: 兼容性风险: 新抽象默认关闭, 现有 CP 路径完全不受影响, 风险低。未实现的方法: `shard_hidden_states` 等方法抛出 `NotImplementedError`, 若在 CP v2 路由启用前被意外调用将崩溃, 但通过后续 PR 逐步填充可避免。环境变量别名: `SGLANG_ENABLE_REFACTOR_CP` 作为已废弃别名保留, 但删除旧环境变量的用户无感知。
- 影响: 用户: 无用户可见变更, 现有命令行参数继续生效。后续 CP v2 启用后将影响 CP 行为。系统: 增加少量内存开销 (策略单例), 无性能影响。团队: 为后续 CP 重构提供统一接口, 降低模型接入成本。
- 风险标记: 新抽象默认关闭, 未实现方法可能误调, 环境变量别名兼容, 测试覆盖率有限, CP v2 尚未启用

关联脉络

- PR #27312 [1/n] [CP] Simplify prefill context parallel server args: 本 PR #27313 依赖于 #27312, 后者简化了 server args 并规范化了 `cp_strategy` 字段。本 PR 在此基础上初始化策略单例。
- PR #27252 [Roadmap] Prefill Context Parallel Refactor: 本 PR 是 Roadmap issue #27252 的第二项, 整体设计遵循该 issue。
- PR #27314 [3/n] [CP] Integrate CP-v2 strategy into model runner: 预期的后续 PR (未在历史中明确, 但根据 roadmap 推测), 将策略抽象集成到模型 runner。