

PR #33171 完整报告

sgl-project/sglang

test: recover the config-namespace-migration deferrals

合并时间: 2026-08-01 23:59

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/33171>

执行摘要

- 一句话: 恢复配置迁移期跳过的 15 个单测文件, 退役 deferral ratchet
- 推荐动作: 值得精读。两类读者收益最大: (1) 正在做大规模内部 API 迁移的团队——deferral ratchet (钉住基线 + 双向断言) 是管理迁移测试债务的极佳实践, 本 PR 展示了它的完整生命周期 (建立、履行、退役); (2) SGLang runtime context 相关开发者——本 PR 是 `override_server_args`、`bag` 断言、各命名空间访问器用法的活教材。`radix cache` 用例的改造尤其值得看: 它展示了当测试在“跳过期”长大、且与生产语义发生冲突时, 如何重新构造等价状态而非强行适配。

功能与动机

PR body 明确说明: 15 个单测文件在 namespace 迁移期间被 `module-skip`, 原因是它们的 `fixture` 注入配置的方式对 namespace accessors 不可见 (伪造 `get_server_args` 模块绑定、`post-publish` 往 `ServerArgs` 实例写字段)。deferral ratchet 将这 15 个文件钉死在基线上, 使债务不能无声增长; 本 PR 全部恢复并退役 ratchet——“its job done — is retired”。

实现拆解

1. 批量恢复 14 个 deferral 文件 (Commit 1, a309036): 删除 `pytestmark = skip` 与 `setUpModule()` 跳过块, 改用三种模式恢复——(a) 配置发布: 通过 `get_context().override_server_args(...).install()` 配合 `addCleanup(override.restore)` 把被测代码读取的配置发布进 runtime context, 作用域仅限本次测试, 涉及 `test_deepseek_v4_shared_expert_fusion.py`、`test_register_to_bootstrap.py`、`test_eagle_worker_v2_topk1_fastpath.py`、`test_fused_moe_triton_config.py`、`test_tbo_filter_batch_marker.py` 等; (b) `bag` 断言: 原断言 `server_args` 实例字段写穿 (如 `server_args.disable_shared_experts_fusion`) 改为断言 `bag` 状态 (如 `get_exec().moe.disable_shared_experts_fusion`), 与 `declare_load_time_override` 的 `bag-only` 语义一致; (c) 桩字段扩充: `test_pool_configurator.py` 的 `model runner` 桩补 `context_len`、`max_total_tokens`, `test_max_running_requests.py` 引入 `_published()` 发布辅助并以 `ps.attn_dp_size` 替代裸 `dp_size`, `test_register_to_bootstrap.py` 用 `kv_cache_dtype_str` 替代 `server_args.kv_cache_dtype` (对应生产代码 `KVArgs payload` 字段迁移)。另有 5 个文件 (`test_mm_process_config.py`、`test_tokenizer_manager_cleanup.py`、`test_dllm_fdfo_kv_reuse.py`、`test_grammar_manager.py`、`test_fp32_lm_head.py`、

test_priority_scheduling_disaggregation.py) 仅删跳过块即可恢复。

2. 单独恢复 radix cache 文件 (Commit 2, 78318da) :

test_unified_radix_cache_unittest.py 在跳过期间长大, 且两个用例与迁移后语义冲突——test_cache_finished_req_strips_thinking (19 个参数化类) 原直写 get_server_args().strip_thinking_cache, 改为 get_serving().override(strip_thinking_cache=True) 的 serving bag 作用域覆盖; test_shallower_crossing_backs_up_above_back_unded_middle 原通过 insert_host 构造“备份链中间断裂”状态, 而 write-through 下 insert_host 会故意丢弃未备份节点下方的 refill (host_insert_dropped), 改为显式 _write_backup + writing_check + evict 构造“中间节点已备份后被设备驱逐”的等价状态。

3. 退役 deferral ratchet: 删除 test/registered/unit/test_migration_deferral_ratchet.py (基线 15 → 0)。该文件此前双向守卫: deferral 数超过基线即失败 (防新 skip 混入), 低于基线也失败 (逼恢复者同步下调基线锁定成果)。

4. 验证与配套: 全部 15 个文件按文件粒度 (CI 语义) 与单进程全量各跑一遍, 证明无跨文件泄漏; radix 文件单文件 1039 个用例通过; 全量套件双跑新增 120 个通过用例。评审中 2 个 P1 (MLX 配置发布与 server_args 占位) 与 3 个自审建议均在最终 head 修复。

关键文件:

- test/registered/unit/test_migration_deferral_ratchet.py (模块 迁移护栏; 类别 test; 类型 deletion; 符号 TestMigrationDeferralRatchet, test_deferred_test_files_match_the_baseline) : 整个守卫文件被删除, 基线 15 → 0, 是迁移债务清零的标志性动作。理解它才能理解本 PR 的治理框架。
- test/registered/unit/mem_cache/test_unified_radix_cache_unittest.py (模块 前缀缓存; 类别 test; 类型 test-coverage; 符号 setUpModule, test_cache_finished_req_strips_thinking, test_shallower_crossing_backs_up_above_back_unded_middle) : 恢复最复杂的文件: 在跳过期间长大了一批 hicache/insert-walk 用例, 两个核心用例因 write-through 语义变化需要重构测试场景而非简单恢复 fixture。
- test/registered/unit/models/test_deepseek_v4_shared_expert_fusion.py (模块 融合策略; 类别 test; 类型 test-coverage; 符号 setUpModule, setUp, tearDown, TestDeepseekV4SharedExpertFusionPolicy) : 最能体现 bag-only 断言模式的恢复样本: 从断言 ServerArgs 实例写穿改为断言 get_exec() 命名空间, 与 declare_load_time_override 语义对齐。
- test/registered/unit/hardware_backend/mlx/test_max_running_requests.py (模块 并发上限; 类别 test; 类型 test-coverage; 符号 setUpModule, _published, _stub, _hybrid_stub_for_initialize) : 评审交锋最集中的文件 (2 个 P1 均在此) : 展示了从 stub.server_args 直写迁移到 _published() 发布辅助 + ps 命名空间的完整模式。
- test/registered/unit/spec/test_eagle_worker_v2_topk1_fastpath.py (模块 投机解码; 类别 test; 类型 test-coverage; 符号 setUpModule, setUp, TestEagleWorkerV2Topk1FastPath, TestEagleWorkerV2BackendFallback) : 展示了 setUp 粒度发布配置的恢复模式, 并含一条有价值的自审讨论 (cuda_graph_max_bs_decode 无效 seed 的处理)。

关键符号: get_context().override_server_args, _published,

TestMigrationDeferralRatchet.test_deferred_test_files_match_the_baseline,

TestEagleWorkerV2Topk1FastPath.setUp, TestRegisterToBootstrap.setUp, test_cache_finished_req_strips_thinking, test_shallower_crossing_backs_up_above_backupped_middle

关键源码片段

test/registered/unit/test_migration_deferral_ratchet.py

整个守卫文件被删除，基线 15 → 0，是迁移债务清零的标志性动作。理解它才能理解本 PR 的治理框架。

- # 该文件随本 PR 整体删除：它把“迁移期间必须跳过的测试”钉死在基线 15 个，
- # 职责完成后退役。以下为删除前的完整逻辑，供理解迁移债务管理机制参考。

```
"""Ratchet guard: config-namespace-migration test deferrals may only decrease."""
```

```
from pathlib import Path
```

```
# 从 test/registered/unit/ 向上两级得到 test/（测试根目录）
```

```
_TEST_ROOT = Path(__file__).resolve().parents[2]
```

```
# 在测试文件里搜索的“延期标记”：凡含此文案的文件即视为迁移 deferral
```

```
_MARKER = "config-namespace migration"
```

```
# 基线 15：与当时被 module-skip 的文件数严格相等
```

```
_BASELINE = 15
```

```
class TestMigrationDeferralRatchet(CustomTestCase):
```

```
    def test_deferred_test_files_match_the_baseline(self):
```

```
        # 全量扫描测试根目录，统计仍带 deferral 标记的文件
```

```
        deferred = sorted(
```

```
            p.relative_to(_TEST_ROOT).as_posix()
```

```
            for p in _TEST_ROOT.rglob("*.py")
```

```
            if p.name != Path(__file__).name and _MARKER in p.read_text(errors="ignore")
```

```
        )
```

```
        count = len(deferred)
```

```
        # 双向守卫：过多 -> 有新的 skip 悄悄混入；过少 -> 恢复的文件没有同步
```

```
        # 下调基线。两条路都会 fail，逼着“恢复一个、锁定一个”。
```

```
        if count > _BASELINE:
```

```
            self.fail(
```

```
                f"deferred (module-skipped) migration tests grew: {count} > "
```

```
                f"baseline {_BASELINE}: {deferred}. Do not add new deferrals."
```

```
            )
```

```
        if count < _BASELINE:
```

```
            self.fail(
```

```
                f"deferred migration tests shrank: {count} < baseline {_BASELINE}. "
```

```
                "Lower the baseline in this file to lock in the recovery."
```

```
            )
```

test/registered/unit/mem_cache/test_unified_radix_cache_unittest.py

恢复最复杂的文件：在跳过期间长大了一批 hicache/insert-walk 用例，两个核心用例因 write-through 语义变化需要重构测试场景而非简单恢复 fixture。

```
# test_cache_finished_req_strips_thinking 的恢复模式：
# 原代码直接写 get_server_args().strip_thinking_cache = True（对 namespace
# accessors 不可见），改为通过 serving bag 的作用域 override 发布配置。
```

```
# cache_finished_req 读取 get_serving().strip_thinking_cache
with get_serving().override(strip_thinking_cache=True):
    avail_before = allocator.available_size()
    cache.cache_finished_req(
        req,
        is_insert=True,
        kv_len_to_handle=req.effective_kv_committed_len(),
    )
    start_p, end_p = req.effective_kv_committed_len(), req.kv.kv_allocated_len
# override 上下文退出后自动还原，无需手动置 False
```

```
# test_shallower_crossing_backs_up_above_backupped_middle 的场景重构：
# 原方案用 insert_host 在“未备份的顶层节点”下方插入备份节点以破坏备份连续性；
# 但 write-through 下 insert_host 会故意丢弃未备份节点下方的 refill
# （host_insert_dropped），因此改为显式 backup + device eviction 构造等价状态。
```

```
self._insert(cache, allocator, req_to_token_pool, [1, 2, 3, 4])
top = next(iter(cache.root_node.children.values()))
# 先插入更深的一层，再显式备份中间的节点
self._insert(cache, allocator, req_to_token_pool, list(range(1, 9)))
middle = next(iter(top.children.values()))
self.assertGreater(_write_backup(cache, middle, write_back=True), 0)
cache.writing_check(write_back=True)
# 把中间的备份节点从设备驱逐，形成“已备份但已被驱逐”的断裂链
cache.evict(EvictParams(num_tokens=4))
self.assertTrue(middle.evicted)
self.assertTrue(middle.backupped)
self.assertFalse(top.backupped)
```

test/registered/unit/models/test_deepseek_v4_shared_expert_fusion.py

最能体现 bag-only 断言模式的恢复样本：从断言 ServerArgs 实例写穿改为断言 get_exec() 命名空间，与 declare_load_time_override 语义对齐。

```
class TestDeepseekV4SharedExpertFusionPolicy(unittest.TestCase):
    """共享专家融合的禁用决策是 load-time 解析：结果落在已发布的配置
    bag 上（declare_load_time_override 只写 bag，ServerArgs 实例保持原样）。"""

    def _make_model(self, n_shared_experts=1):
        return SimpleNamespace(
            config=SimpleNamespace(n_shared_experts=n_shared_experts)
        )
```

```

def _publish(self, enforce):
    # 通过 runtime context 发布配置：不再跳过模块、不再往 ServerArgs
    # 实例上写属性，而是发布生产代码真正读取的配置命名空间
    override = get_context().override_server_args(
        enforce_shared_experts_fusion=enforce
    )
    override.install() # 激活本次 override
    self.addCleanup(override.restore) # 测试结束自动还原，避免跨用例泄漏

def test_disables_shared_fusion_without_enforce(self):
    self._publish(enforce=False)
    model = self._make_model()

    DeepseekV4ForCausalLM.determine_num_fused_shared_experts(model)

    self.assertEqual(model.num_fused_shared_experts, 0)
    # bag-only 断言：不再读 server_args 实例字段，改读 get_exec() 的
    # moe 命名空间，与生产代码的读取路径保持一致
    self.assertTrue(get_exec().moe.disable_shared_experts_fusion)

def test_enables_shared_fusion_when_enforced(self):
    self._publish(enforce=True)
    model = self._make_model()

    DeepseekV4ForCausalLM.determine_num_fused_shared_experts(model)

    self.assertEqual(model.num_fused_shared_experts, 1)
    self.assertFalse(get_exec().moe.disable_shared_experts_fusion)

```

评论区精华

评审主要交锋集中在“恢复后的 fixture 是否真的发布了生产代码所读的配置”：Codex 机器人提出 2 个 P1（MLX resolver 测试缺配置发布与 `ps.attn_dp_size`、`initialize()` 桩缺 `server_args` 占位导致 `AttributeError`），作者均修复并注明占位字段“整对象求值但从从不读取”；作者自审发现 EAGLE setUp 中 `cuda_graph_max_bs_decode=8` 是无效 seed（生产读 `get_exec().graph.cuda_graph_config.decode.max_bs`，快速字段不会被 `override_server_args` 重新折叠），修复为删除无效字段并加注释；另有 2 个关于注释与 bag/raw 读取语义的 nit 类线程，作者逐一核对 #33170 栈上代码后确认或撤回，最终 r3 为零开放问题。

- MLX 回归测试恢复需发布配置并补齐 parallel 状态 (correctness): 作者新增 `_published()` 辅助，围绕每个 `resolve/initialize` 调用发布配置；stub 改携带 `_` 前缀字段与 `ps = SimpleNamespace(attn_dp_size=...)`。
- initialize 桩缺 `server_args` 占位导致 `AttributeError` (correctness): 作者恢复为空 `SimpleNamespace` 占位，并注释“整对象作为调用参数求值但从从不读取”。
- EAGLE setUp 中 `cuda_graph_max_bs_decode` 是无效 seed (correctness): 作者删除无效字段，注释说明 dummy-boundary publish 不解析，`cuda_graph_config` 为 `None`，

max_running_requests 单独决定预分配尺寸。

- register_to_bootstrap setUp 注释与生产读取语义的核对 (question): 作者核实后撤回: conn.py 在 #33170 已翻转为 bag 读取, 无 self.server_args 读取残留, 删除死的 MagicMock 块; 保留有用的显式 seed (load_balance_method + port=30000) 。
- tbo filter_batch 注释中 raw-vs-bag 的说法 (documentation): 作者在 stack 上验证: two_batch_overlap.py 中 attention_backend 走 get_server_args() (per-runner fork 字段保持 raw)、moe_dense_tp_size 走 get_parallel() (#33170 翻转), 注释与代码匹配, r2 作者承认误报并撤回。

风险与影响

- 风险:
 1. MLX 平台验证盲区: test_max_running_requests.py 依赖 mlx 安装, CI 的 CPU 套件不会实际执行; _hybrid_stub_for_initialize 中空 server_args 占位是按“整对象求值但不读取”的假设维护的, 若生产代码后续真的读取该字段, 表现为 AttributeError (fail 而非误通过), 方向安全但依赖 MLX CI 真机覆盖。
 2. radix 用例语义改造: test_shallower_crossing_backs_up_above_backupted_middle 从 insert_host 路径改为显式 backup + evict 构造, 若 _write_backup 与真实 write-through 语义有偏差, 该用例对“备份连续性破坏”的回归覆盖可能与生产行为不完全等价。
 3. 上游 stack 依赖: 多个断言 (如 get_parallel().moe_dense_tp_size、get_exec().moe.disable_shared_experts_fusion) 依赖 #33170 已合入的 bag 读取语义, 栈内后续 PR 若调整命名空间, 本批测试需同步跟进。整体为纯测试变更, 无生产代码、无运行时行为风险。 - 影响: 对 CI: 约 120 个此前从未运行的用例重新进入全量套件, 覆盖调度 (priority scheduling)、radix cache、EAGLE 投机解码、TBO 批重叠、MoE Triton 配置、disaggregation 注册、MLX 并发上限等多模块, 等于给迁移后的配置读取路径补上了缺失的回归保护。对团队: ratchet 退役标志迁移债务清零, 后续新测试不得再以“迁移期间”为由 module-skip, 必须走 override_server_args 发布模式。对用户: 无直接运行时影响。 - 风险标记: 测试恢复覆盖面大, MLX 平台验证受限, 依赖上游 stack 语义, radix 用例语义改造

关联脉络

- PR #33170 Base PR of the config-namespace follow-up stack: 本 PR 的 base, 已将 register_to_bootstrap 等生产代码翻转为 bag 读取; 本 PR 多个断言与注释的语义前提均来自它。
- PR #33013 config: read resolved config via namespace accessors: config 读取迁移主 PR, 本 PR 恢复的 15 个 deferral 测试正是其迁移期间逃逸的回归覆盖。
- PR #33011 config: preserve resolved config across nested publishes + mutation ratchets: 与本 PR 退役的 deferral ratchet 同属迁移护栏体系, 后者建立 ratchet 模式, 本 PR 展示其退役。
- PR #33172 runtime_context: per-role namespace enforcement behind SGLANG_ROLE_NAMESPACES: 同栈 Part 3 (RFC #30696 follow-up), 本 PR 恢复的

测试为其提供了配置读取路径的回归保障。

- PR #33179 [CI] Fix runtime context setup in flat logprob tests: 同类“迁移后测试收尾”PR, 修复 flat logprob 测试在 runtime context 迁移后的失败, 与本 PR 共同构成迁移完成态。