

PR #36618 完整报告

sgl-project/sglang

config: resolution declares, and nothing writes a field

合并时间: 2026-08-28 03:53

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/36618>

执行摘要

- 一句话: 重构配置解析: resolution 只声明不写字段
- 推荐动作: 值得精读。重点看三点: run_post_process_pass 的 published 拒绝设计 (含与 declare_late_resolution 的对称性)、契约测试的双方向验证 + 注入法 (先证明两个方向独立失败再断言)、test_chain_read_ratchet.py 用 AST 强制调用形状以保证扫描完备性的思路。注意 2 条未解决的 P2 review 评论, 尤其是顺序启动回归, 在后续 PR 中确认是否修复。

功能与动机

PR body 明确说明: 此前的系列改造已让 `ServerArgs` 持有 operator 输入、解析答案进入 declaration stash, 但仍有两条通道会在之后写字段, 且没有任何断言约束结果 ("Two channels could still write a field afterwards, and nothing asserted the result")。本 PR 关闭这两条通道并补上断言; 同时修复 `_a2a_fusion_adjustments` 与 `_hrm_text_attention_force` 未被 `@register_post_process` 注册、导致所有枚举 `POST_PROCESS_PASSES` 的检查绕过它们的 registry 漏洞。

实现拆解

实现分四步:

1. 删除写穿逻辑 (核心): `python/sglang/srt/arg_groups/overrides.py` 中 `run_post_process_pass` 不再在 `_resolution_finished` 时调用 `_apply_fields` 写回字段。解析后的 pass 声明统一进入 `_resolved_overrides` stash, `publish` 从 stash 投影 config bags; `_apply_fields` 保留给 `RuntimeContext.override_server_args` (测试 launch 替身) 这一个调用方。同时新增对 published record 的拒绝: 若 `get_context().server_args` 就是当前对象, 直接 raise `ValueError`, 因为 publish 之后 stash 不会再被投影, 追加声明是静默 no-op, post-publish 变更应走 `get_context().override(...)`。
2. 修正 registry 语义: `POST_PROCESS_PASSES` 注释从 "end-state execution order" 改为 "registry, not an execution order"——实测 `_hispase_validation` 注册第 16 位但总是最后执行, 因为 `check_server_args` 阶段晚于 `__post_init__`。PR body 说明 `_a2a_fusion_adjustments` 与 `_hrm_text_attention_force` 已补上 `@register_post_process` (diff 摘要窗口未完整展示该 hunk)。

3. 新增契约测试: `test/registered/unit/server_args/test_record_holds_the_raw_input.py` (新增) 用 15 种 launch shape 断言 `resolve_once()` 后每个字段仍与 `_raw_input` 快照一致, 覆盖两个独立方向——字段不得被重新绑定 (rebind)、调用方传入的可变对象不得被原地修改 (in-place edit, 快照引用同一对象因此逐字段比较不可见), 并通过 `setattr / cuda_graph_config.setdefault` 注入验证两个方向独立失败。
4. 注册覆盖扫描与配套测试 / 文档: `test/registered/unit/test_chain_read_ratchet.py` 新增 `_passes_named_at_call_sites()` AST 扫描 (强制 `run_post_process_pass` 第二参数为裸名字, 否则硬失败) 与 `TestEveryInvokedPassIsRegistered`, 以调用点为 ground truth 双向校验 registry; `test_model_overrides.py` 将 `test_post_materialize_pass_writes_through` 反转为 `test_a_pass_after_resolution_declares_without_writing`, 断言 pass 后字段保持原始值; `.claude/skills/sglang-runtime-context/SKILL.md` 修正 `publish` 描述为“从声明投影, 而非快照 resolved values”。

配套验证: 24 种 launch shape × 478 个共享字段的 resolution dump 与基线 `f775db03aaa` 逐字段比较 0 差异 (唯一新增字段 `grpc_worker_threads` 两侧值均为 4); 所有 guard 在系列每个 commit 上单独运行通过。

关键文件:

- `python/sglang/srt/arg_groups/overrides.py` (模块 配置解析; 类别 source; 类型 core-logic; 符号 `run_post_process_pass`, `_apply_fields`, `POST_PROCESS_PASSES`, `register_post_process`): 唯一生产代码变更: 删除 `run_post_process_pass` 的字段写穿、新增 `published record` 拒绝、修正 `POST_PROCESS_PASSES` 的 registry 语义, 是系列契约的承重墙。
- `test/registered/unit/server_args/test_record_holds_the_raw_input.py` (模块 契约测试; 类别 test; 类型 test-coverage; 符号 `TestRecordHoldsTheRawInput`, `setUp`, `restore`, `_model_path`): 新增的核心契约测试: 15 种 launch shape 断言 `resolve_once()` 后每个字段仍等于调用方传入的 `_raw_input` 快照, 双方向验证 (rebind 与 in-place edit)。
- `test/registered/unit/test_chain_read_ratchet.py` (模块 链读约束; 类别 test; 类型 test-coverage; 符号 `_passes_named_at_call_sites`, `TestEveryInvokedPassIsRegistered`, `test_the_registry_covers_every_call_site`): 新增 registry 覆盖扫描: 以 `run_post_process_pass` 调用点为 ground truth, AST 强制调用形状并双向校验 `POST_PROCESS_PASSES`, 堵住未注册 pass 绕过检查的漏洞。
- `test/registered/unit/test_model_overrides.py` (模块 模型覆盖; 类别 test; 类型 test-coverage; 符号 `test_post_materialize_pass_writes_through`, `test_a_pass_after_resolution_declares_without_writing`): 将写穿断言反转为声明不写字段断言, 验证 resolution 后 pass 只进 stash 不碰字段, 是核心行为变更的直接测试佐证。
- `.claude/skills/sglang-runtime-context/SKILL.md` (模块 技能文档; 类别 docs; 类型 documentation): 修正 `publish` 语义描述: 从声明投影而非快照 resolved values, 避免开发者按旧描述在 record 上找解析结果。

关键符号: `run_post_process_pass`, `_apply_fields`, `_passes_named_at_call_sites`, `TestEveryInvokedPassIsRegistered.test_the_registry_covers_every_call_site`, `TestRecordHoldsTheRawInput.test_no_field_moves_from_what_the_caller_passed`, `TestRecordHoldsTheRawInput.test_the_snapshot_is_the_value_the_caller_passed`,

test_a_pass_after_resolution_declares_without_writing

关键源码片段

[python/sclang/srt/arg_groups/overrides.py](#)

唯一生产代码变更：删除 `run_post_process_pass` 的字段写穿、新增 `published record` 拒绝、修正 `POST_PROCESS_PASSES` 的 `registry` 语义，是系列契约的承重墙。

```
def run_post_process_pass(server_args: Any, fn: Callable[..., dict]) -> None:
    """在遗留 handler 槽位上调用一个 post-process pass。
```

```
pass 在解析态视图（叠加了 stash 中已累积声明）上求值，并把它的声明
追加进 stash —— config bags 正是从 stash 投影出来的。字段本身保持不动。
"""
```

```
from sclang.srt.runtime_context import get_context
```

```
# 拒绝已发布（published）的 record：publish 之后 stash 不会再被投影，
# 此时追加声明会成为静默 no-op，因此直接报错，引导代码改走
# get_context().override(...) 更新 bags。
```

```
try:
```

```
    published = get_context().server_args
```

```
except ValueError:
```

```
    published = None
```

```
if published is server_args:
```

```
    raise ValueError(
        f"run_post_process_pass({fn.__qualname__!r}) called on the published "
        "config; the stash is projected at publish and never again, so a "
        "declaration made here would be a silent no-op -- post-publish "
        "changes go to the bags via get_context().override(...)"
    )
```

```
# 在叠加了声明 overlay 的只读视图上求值，pass 只返回声明 dict，不许改字段。
```

```
declared = fn(ResolvedView(server_args, overlay=_declaration_overlay(server_args)))
```

```
if not isinstance(declared, dict):
```

```
    raise TypeError(
        f"post-process pass {fn.__qualname__} must return a dict, "
        f"got {type(declared).__name__}"
    )
```

```
if declared:
```

```
    entry = (fn.__qualname__, dict(declared))
```

```
    stash = getattr(server_args, "_resolved_overrides", None)
```

```
    if stash is None:
```

```
        # 直接作用于 fixture 的 pass 槽位可能从未经过 monolith dispatch
        # （dispatch 负责初始化 stash），这里惰性创建；真实 publish 一定
        # 先过 dispatch，所以 pass 槽位必须位于 __post_init__ 中
        # dispatch 之后。
```

```
        stash = server_args._resolved_overrides = []
```

```
    stash.append(entry)
```

```
    validate_declarations(server_args, [entry])
```

test/registered/unit/server_args/test_record_holds_the_raw_input.py

新增的核心契约测试：15 种 launch shape 断言 resolve_once() 后每个字段仍等于调用方传入的 _raw_input 快照，双方向验证（rebind 与 in-place edit）。

```
def _moved(current, original):
    """判断字段是否不再等于调用方传入的原始值。

    对可变对象（list / dict / set / bytearray）要求同一对象（is 判定）：
    等值拷贝不再与调用方共享内存，record 的原地修改会污染调用方数据，
    因此也算 moved；对 int / str 等不可变类型退化为值比较
    （相等的 int / str 不一定是同一对象）。
    """
    if current is original:
        return False
    if isinstance(original, (list, dict, set, bytearray)) or isinstance(
        current, (list, dict, set, bytearray)
    ):
        # 可变对象只有“同一个对象”才算未移动：等值拷贝已不再与调用方共享。
        return True
    # 不可变类型的相等即视为未移动。
    return current != original
```

```
def test_no_field_moves_from_what_the_caller_passed(self):
    # 遍历 15 种 handler 家族对应的 launch shape，逐字段比对解析后的 record
    # 与解析前快照 _raw_input；任何字段被改写都意味着 record 不再回答
    # operator 的输入，决策者读它会与 config bags 不一致。
    for name, supplied in _SHAPES.items():
        with self.subTest(shape=name):
            server_args = self._resolve(**supplied)
            raw = server_args._raw_input
            moved = {
                field.name: (raw[field.name], getattr(server_args, field.name))
                for field in dataclasses.fields(server_args)
                if _moved(getattr(server_args, field.name), raw[field.name])
            }
            self.assertEqual(
                {},
                moved,
                f"resolution moved these fields on the {name} shape, so the "
                "record no longer answers with the operator's input and a "
                "reader that takes a decision off it disagrees with the bags: "
                f"{moved}",
            )
```

test/registered/unit/test_model_overrides.py

将写穿断言反转为声明不写字段断言，验证 resolution 后 pass 只进 stash 不碰字段，是核心行为变更的直接测试佐证。

```

def test_a_pass_after_resolution_declares_without_writing(self):
    from sglang.srt.arg_groups.overrides import run_post_process_pass

    sa = self._construct("LlamaForCausalLM", "llama")
    raw_before = sa.attention_backend

    def _force_triton(view):
        # pass 只返回声明 dict, 不再负责写字段。
        return {"attention_backend": "triton"}

    run_post_process_pass(sa, _force_triton)

    # 解析视图读到新值、publish 投影出的 leaf 也是新值……
    self.assertEqual("triton", self._resolved(sa, "attention_backend"))
    self.assertEqual(
        (self._publish(sa), self._leaf("attention_backend"))[1], "triton"
    )
    # ……但 record 字段保持调用方原始输入, 这是本 PR 的核心契约。
    self.assertEqual(
        raw_before,
        sa.attention_backend,
        "the pass wrote the field, so the record stopped answering with the "
        "operator's input",
    )

```

评论区精华

两轮 Codex 自动 review 均未人工回复, 各提出 1 个未解决的 P2 问题:

1. 等值替换检测盲区: test_record_holds_the_raw_input.py 的 _moved 对 mutable 做 is not 判定, 但若 resolver 用等值拷贝替换 (如 self.lora_paths = list(self.lora_paths)), is not 为真、相等性为假, guard 放行, record 不再引用 operator 原对象, 与声明的 no-rebinding 契约矛盾。建议 identity 变化即视为 moved。
 2. 顺序启动回归: overrides.py:241 的 published guard 在 Engine.shutdown() 后重建同一 ServerArgs 实例时误触发——runtime context 未重置, _launch_subprocesses() 在 republish 前调用 check_server_args(), _hisparse_validation 走到该 guard 直接 raise, 破坏 sequential launch。
- P2: 等值替换的 mutable 未被判定为 moved (correctness): 未解决, 无后续回复; 测试契约对 identity 替换存在盲区。
 - P2: 顺序启动 (Engine 重建) 会误触发 published guard (correctness): 未解决, 无后续回复; 启动路径存在直接失败风险。

风险与影响

- 风险:
 1. 顺序启动回归 (未解决): review 指出的 Engine 关停后同实例重建会误触发 run_post_process_pass 的 published 拒绝, 属于启动路径直接失败, 影响面大。

2. mutable 等值替换盲区（未解决）：契约测试的 `_moved` 判定漏检 `list()` / `dict()` 拷贝替换，违反本 PR 核心契约，后续系列重写可能依赖该护栏。
3. 模型族特定分支覆盖不足：`_hrm_text_attention_force` 只对单一模型族运行，`runtime spy` 用 Llama fixture 无法触达，只能靠静态扫描补位；一旦有未注册 pass 落入该分支仍有绕过风险。
4. `_hispase_validation` 行为变化：从写穿改为纯声明，依赖字段读值的代码若未被 bags 投影覆盖会读到原始输入；PR 已用 24 shape 验证，但真实进程组（process group）路径 CPU 测试覆盖不到。
 - 影响：对开发者：确立 " 字段永不写 " 的声明式解析契约，是后续 4 个 PR（118 文件机械重写、301 处调用点改造）的前置地基；所有 handler 必须通过 `@register_post_process` + 声明返回，读配置走 `config bags`。对系统：ServerArgs 保持 operator 原始输入，解析结果只存于 stash，publish 为唯一投影点。
 - 对测试体系：新增契约测试与 AST 扫描作为防回归护栏，后续每个 commit 都必须绿。
 - 风险标记：顺序启动回归风险，等值替换检测盲区，模型族特定分支测试盲区，核心配置路径变更

关联脉络

- PR #36725 config: every handler declares its cuda-graph decisions: 同 5-PR 系列第 2 个，cuda-graph 决策改由各 handler 显式声明，依赖本 PR 确立的 " 只声明不写字段 " 契约。
- PR #36620 config: a parallel leaf with no live counterpart is read bare: 同 5-PR 系列第 3 个，118 文件机械重写的前提是本 PR 的字段不变式。
- PR #36621 config: a parallel size has one spelling; a patched scope declares its own: 同 5-PR 系列第 4 个，由第 3 个 PR 的重写所支撑的设计变更。
- PR #36622 config: the record is not an object that gets passed around: 同 5-PR 系列第 5 个，清理 ServerArgs 传递链；PR body 明确提及它解释为何 `_apply_fields` 最后一个调用方需单独处理。