

PR #33336 完整报告

sgl-project/sglang

config: keep runtime hicache and weight-version updates off ServerArgs

合并时间: 2026-08-03 12:23

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/33336>

执行摘要

- 一句话: 配置更新迁出 ServerArgs, 按作用域分置存储
- 推荐动作: 值得精读。两个亮点: 一是「进程级 bags vs per-engine manager」双轨配置归属的设计, 直接决定多引擎共享 tokenizer 进程场景下的正确性; 二是源码级守卫测试 (TestControlPlaneFieldsAreNotReadFromTheInstance) 用枚举模块 + 正则扫描把「静默过期读回」这类无报错回归钉死, 该模式可复制到其他配置迁移场景。建议连同 #33337 (FPM 端点入 bags) 与 #33338 (清除最后进程级配置读取) 一起阅读, 纵览 5 步系列全貌。

功能与动机

PR body 明确指出问题根源: 运行时控制面变更此前直接改写 `ServerArgs` 实例, 目的是让 readback 显示新值, 但两边作用域不同——调度器侧直写实例时 namespace 读者 (`get_memory()`) 看不到变更, tokenizer 侧若写进程级 bags 又会因「several Engines can share one tokenizer process」把一引擎的变更泄漏进另一引擎的读回。此外 GitHub 将 chained-base 系列视为 stack, 阻塞 base retargeting 与合并路径, 前身 #33240 只能关闭, 本 PR 改为基于 main 重提, 代码与其最终版一致。

实现拆解

1. 调度器侧: HiCache attach/detach 落入进程级 config bags。
`python/sglang/srt/managers/scheduler.py` 的 `attach_hicache_storage_wrapped` 与 `detach_hicache_storage_wrapped` 把 `self.server_args.override("scheduler.attach_hicache", ...)` 换成 `get_context().override(...)`。因为 `get_internal_state` 本来就报告 `get_context().resolved_server_args_dict()`, 这一改让 `get_memory()` 等 namespace 读者与 resolved-config 读回同时看到变更, 而发布出去的 `ServerArgs` 实例保持启动原样。
2. Tokenizer 侧: per-engine 更新沉淀在 Manager 上。
`python/sglang/srt/managers/tokenizer_manager.py` 新增模块级 `_SERVER_ARGS_FIELDS` (由 `ServerArgs` dataclass 字段名构成的白名单) 与 `_MANAGER_OWNED_FIELDS` (`model_path`、`served_model_name`), `__init__` 增加 `self._config_updates` 列表。四个新方法: `record_config_updates(source, **fields)` 拒绝未知字段 (防止 overlay 出幻影配置项) 后追加记录; `config_value(name)` 按「更新优先、启动配置兜底」读单字段; `resolved_config_dict(base)` 把序列化 `ServerArgs` 当基座叠加更新; `_dump_config_snapshot()` 为转储生成配置快照。`_update_model_path_info` 改为只记录 `load_format` (路径字段走 `_MANAGER_OWNED_FIELDS`),

`update_weights_from_disk` 的 `load_format` 默认值、
`_handle_batch_output/_handle_abort_req` 的 `meta_info["weight_version"]` 全部切到
`config_value`。`tokenizer_control_mixin.py` 的 `HiCache mirror attach/detach` 与
`_update_weight_version_if_provided` 三处写入同步改为 `record_config_updates`。

3. 读回端点整体切换 `overlay` 读取。`http_server.py`: `/server_info` 用
`resolved_config_dict(dataclasses.asdict(server_args))` 生成返回体, `/model_info` 的
`weight_version` 用 `config_value` (顺带删掉重复键), `/hicache/storage-backend` 用循环
`config_value` 读四个 `HiCache` 字段, `/update_weight_version` 改用
`record_config_updates`。`grpc_bridge.py` 的 `get_model_info/get_server_info`、
`engine.py` 的 `get_server_info` 同样切换; `serving_chat/serving_classify/realtime`
`session` 的模型名读回也有小改。
4. 崩溃转储增强与降级路径。`_dump_data_to_file` 与 `dump_requests_before_crash` 的
`payload` 新增 `config_updates` 与 `resolved_config` 两个字段; 当 `ServerArgs` 含不可
`pickle` 对象 (如 `--custom-sigquit-handler` 的 `lambda`) 时, 回退逻辑同时把 `server_args`
与 `resolved_config` 置 `None`, 确保请求数据仍能落盘。
5. 测试与守卫。新增 `test_tokenizer_config_updates.py` (216 行, 覆盖 `overlay` 语义、实例
不被改写、双引擎隔离、`detach` 读回、未知字段拒绝、`dump` 降级, 以及核心守卫类
`TestControlPlaneFieldsAreNotReadFromTheInstance`——正则扫描 7 个 `readback` 模块
, 禁止 8 个控制面字段直读 `self.server_args`)、`test_scheduler_hicache_attach.py` (
`attach/detach` 后 `namespace` 读者与 `readback` 一致); `test_server_info.py` 的桩从
`SimpleNamespace` 换成真实 `TokenizerManager`; `test_forward_pass_metrics.py` 改为发
布真实配置 (按 `body` 描述); `writer ratchet` 从 26 降到 19。

关键文件:

- `python/sglang/srt/managers/tokenizer_manager.py` (模块 配置管理; 类别 `source`; 类
型 `core-logic`; 符号 `record_config_updates`, `config_value`, `_dump_config_snapshot`,
`resolved_config_dict`): 核心源码文件: 新增 `per-engine` 配置更新记录机制 (
`record_config_updates/config_value/resolved_config_dict/_dump_config_snapshot`),
并将 `weight_version`、`load_format` 等读回切换为 `overlay` 读取, 同时增强崩溃转储
`payload`。
- `test/registered/unit/managers/test_tokenizer_config_updates.py` (模块 配置管理; 类别
`test`; 类型 `test-coverage`; 符号 `TestTokenizerConfigUpdates`,
`TestControlPlaneFieldsAreNotReadFromTheInstance`, `CONTROL_PLANE_FIELDS`,
`READMEBACK_MODULES`): 新增 216 行测试: 覆盖 `overlay` 语义、`ServerArgs` 实例不
被改写、双引擎隔离、`detach` 读回、未知字段拒绝、`dump` 降级, 并内置源码级守卫测试禁
止 `readback` 模块直读控制面字段。
- `test/registered/unit/managers/test_scheduler_hicache_attach.py` (模块 调度器; 类别
`test`; 类型 `test-coverage`; 符号 `TestSchedulerHiCacheAttach`,
`test_attach_reaches_the_namespace_readers`,
`test_detach_clears_the_backend_for_the_same_readers`): 新增 76 行测试: 验证
`HiCache attach/detach` 经 `get_context().override` 后 `namespace` 读者 (`get_memory`)
与 `resolved-config readback` 一致、`ServerArgs` 实例保持原样。

- python/sglang/srt/entrypoints/http_server.py (模块 入口端点; 类别 source; 类型 core-logic; 符号 model_info, server_info, hicache_storage_backend_status, update_weight_version) : HTTP 读回端点集中切换: /server_info 用 resolved_config_dict、/model_info 与 /hicache/storage-backend 用 config_value、/update_weight_version 用 record_config_updates, 是外部消费者直接面对的行为变更面。
- python/sglang/srt/managers/scheduler.py (模块 调度器; 类别 source; 类型 core-logic ; 符号 attach_hicache_storage_wrapped, detach_hicache_storage_wrapped) : 调度器侧 HiCache attach/detach 的写入目标从 self.server_args.override 改为 get_context().override, 让 namespace 读者与读回端点同时看到变更。
- python/sglang/srt/managers/tokenizer_control_mixin.py (模块 配置管理; 类别 source ; 类型 core-logic; 符号 attach_hicache_storage, detach_hicache_storage, _update_weight_version_if_provided) : tokenizer 侧 HiCache mirror attach/detach 与 weight version 更新从 server_args.override 改为 record_config_updates, 是本 PR per-engine 语义的直接落点。
- python/sglang/srt/entrypoints/grpc_bridge.py (模块 入口端点; 类别 source; 类型 core-logic; 符号 get_model_info, get_server_info) : gRPC 读回端点 get_model_info/get_server_info 同步切换为 config_value / resolved_config_dict, 保持与 HTTP 端点行为一致。
- python/sglang/srt/entrypoints/engine.py (模块 入口端点; 类别 source; 类型 core-logic ; 符号 get_server_info) : Engine.get_server_info 改用 resolved_config_dict, 保证 Python API 层读回与 HTTP/gRPC 一致。
- python/sglang/srt/runtime_context.py (模块 配置管理; 类别 source; 类型 core-logic; 符号 resolved_server_args_dict) : resolved_server_args_dict 的 docstring 更新, 明确进程级 bags 与 per-engine manager 是两套独立日志、刻意不合并。
- test/registered/unit/entrypoints/test_server_info.py (模块 入口端点; 类别 test; 类型 test-coverage; 符号 TestServerInfoControlPlaneUpdates, _call_server_info_with) : 测试桩从 SimpleNamespace 换成真实 TokenizerManager, 使 overlay 用例不会与生产代码漂移, 并新增 control-plane overlay 用例。
- test/registered/unit/test_server_args_writer_ratchet.py (模块 配置管理; 类别 test; 类型 test-coverage) : writer ratchet 从 26 降到 19, 锁定剩余 ServerArgs 写入点数量, 防止本 PR 的工作回退。

关键符号: record_config_updates, config_value, resolved_config_dict, _dump_config_snapshot, attach_hicache_storage_wrapped, detach_hicache_storage_wrapped, attach_hicache_storage, detach_hicache_storage, _update_weight_version_if_provided, _update_model_path_info, update_weights_from_disk, model_info, server_info, hicache_storage_backend_status, update_weight_version, get_server_info, get_model_info, _handle_batch_output, _handle_abort_req

关键源码片段

[python/sglang/srt/managers/tokenizer_manager.py](#)

核心源码文件：新增 per-engine 配置更新记录机制（record_config_updates/config_value/resolved_config_dict/_dump_config_snapshot），并将 weight_version、load_format 等读回切换为 overlay 读取，同时增强崩溃转储 payload。

```
# ServerArgs 的字段白名单：控制面更新只能落在这些已声明字段上
# （防止未知键在 /server_info 的 overlay 中变成“幻影配置项”）
_SERVER_ARGS_FIELDS = frozenset(f.name for f in dataclasses.fields(ServerArgs))

# 这两个字段由 Manager 直接持有（属性即事实来源），不走 overlay 列表
_MANAGER_OWNED_FIELDS = ("model_path", "served_model_name")
```

```
class TokenizerManager(TokenizerControlMixin, TokenizerManagerScoreMixin):
```

```
    def record_config_updates(self, source: str, **fields) -> None:
```

```
        """记录一次运行期控制面变更（per-engine 语义）。
```

```
        多个 Engine 可共享同一个 tokenizer 进程，所以不能写进程级
        config bags（会串到别的 Engine 的 readback）；变更先攒在
        本 Manager 上，由读回端点以 overlay 方式叠加展示。
        """
```

```
        unknown = sorted(f for f in fields if f not in _SERVER_ARGS_FIELDS)
```

```
        if unknown:
```

```
            raise ValueError(
```

```
                f"{unknown} are not ServerArgs fields; the readback endpoints "
```

```
                "overlay these onto a serialized ServerArgs, so an unknown key "
```

```
                "would surface as a phantom config entry."
            )
```

```
        self._config_updates.append((source, dict(fields)))
```

```
    def config_value(self, name: str):
```

```
        """读取单个字段的生效值：控制面更新优先，其次启动配置兜底。"""
```

```
        if name in _MANAGER_OWNED_FIELDS:
```

```
            return getattr(self, name)
```

```
        for _source, fields in reversed(self._config_updates):
```

```
            if name in fields:
```

```
                return fields[name]
```

```
        return getattr(self.server_args, name)
```

```
    def resolved_config_dict(self, base: Dict[str, Any]) -> Dict[str, Any]:
```

```
        """把序列化后的 ServerArgs 作为基底，叠加上本引擎的控制面更新。
```

```
        /server_info、gRPC get_server_info 等都以此生成返回体，
        保证读回反映当前生效配置而不是启动记录。
        """
```

```
        resolved = dict(base)
```

```
        for _source, fields in self._config_updates:
```

```
            resolved.update(fields)
```

```
        for name in _MANAGER_OWNED_FIELDS:
```

```
            resolved[name] = getattr(self, name)
```

```
return resolved
```

test/registered/unit/managers/test_tokenizer_config_updates.py

新增 216 行测试：覆盖 overlay 语义、ServerArgs 实例不被改写、双引擎隔离、detach 读回、未知字段拒绝、dump 降级，并内置源码级守卫测试禁止 readback 模块直读控制面字段。

```
# 运行期会变化的控制面字段清单：这些字段一律禁止从 ServerArgs 实例直读
```

```
CONTROL_PLANE_FIELDS = (  
    "weight_version",  
    "model_path",  
    "served_model_name",  
    "load_format",  
    "hcache_storage_backend",  
    "hcache_storage_backend_extra_config",  
    "hcache_storage_prefetch_policy",  
    "hcache_write_policy",  
)
```

```
# 豁免行：Prometheus label 集合必须与序列同生命周期固定，
```

```
# 因此 metrics collector 保留服务启动时的名字是刻意为之
```

```
EXEMPT_LINES = (  
    (  
        "srt/managers/tokenizer_manager.py",  
        '"model_name": self.server_args.served_model_name',  
    ),  
)
```

```
class TestControlPlaneFieldsAreNotReadFromTheInstance(CustomTestCase):
```

```
    def test_readbacks_go_through_the_manager(self):
```

```
        # 扫遍所有读回模块的源码，抓到任何直读
```

```
        # self.server_args.< 控制面字段 > 的地方——失败模式是
```

```
        # 静默过期读回（不报错、只返回旧值），值得用守卫测试钉死
```

```
        root = Path(next(iter(sglang.__path__)))
```

```
        patterns = [  
            re.compile(  
                rf"self\.server_args\.{f}\btokenizer_manager\.server_args\.{f}\b"
```

```
            )
```

```
            for f in CONTROL_PLANE_FIELDS  
        ]
```

```
        stale = []
```

```
        for rel in READBACK_MODULES:
```

```
            paths = (  
                sorted((root / rel).rglob("*.py"))  
                if (root / rel).is_dir()  
                else [root / rel]  
            )
```

```
            for path in paths:
```

```
                for number, line in enumerate(path.read_text().split("\n"), 1):
```

```

        if any(
            rel_exempt == path.relative_to(root).as_posix()
            and needle in line
            for rel_exempt, needle in EXEMPT_LINES
        ):
            continue
        if any(p.search(line) for p in patterns):
            stale.append(
                f"{path.relative_to(root)}:{number}: {line.strip()}"
            )
    self.assertEqual(
        stale,
        [],
        "control-plane fields change at runtime and the update lives on the "
        "TokenizerManager; read them with config_value() / "
        "resolved_config_dict() so the readback reflects the change:\n"
        + "\n".join(stale),
    )

```

test/registered/unit/managers/test_scheduler_hicache_attach.py

新增 76 行测试：验证 HiCache attach/detach 经 get_context().override 后 namespace 读者 (get_memory) 与 resolved-config readback 一致、ServerArgs 实例保持原样。

```

class TestSchedulerHiCacheAttach(CustomTestCase):
    def _scheduler(self, **fields):
        # 测试专用：向 config tiers 发布一份携带指定字段的 ServerArgs
        # (install 替换当前槽位, restore 还原), 再用 __new__ 绕过真实
        # 构造函数拼装出被测方法所需的最小 Scheduler 实例
        override = get_context().override_server_args(
            enable_hierarchical_cache=True, **fields
        )
        self.server_args = override.install()
        self.addCleanup(override.restore)

        scheduler = Scheduler.__new__(Scheduler)
        scheduler.server_args = self.server_args
        scheduler.enable_hierarchical_cache = True
        scheduler.enable_hicache_storage = False
        scheduler.is_fully_idle = lambda: True
        scheduler.tree_cache = SimpleNamespace(
            attach_storage_backend=lambda **kwargs: (True, "attached"),
            detach_storage_backend=lambda: (True, "detached"),
        )
        return scheduler

    def test_attach_reaches_the_namespace_readers(self):
        scheduler = self._scheduler(hicache_storage_backend=None)
        out = scheduler.attach_hicache_storage_wrapped(
            AttachHiCacheStorageReqInput(

```

```

        hicache_storage_backend="file",
        hicache_write_policy="write_through",
    )
)
self.assertTrue(out.success)
# 关键断言：namespace 读者 (get_memory) 与 resolved-config readback
# 都能看到后端已挂载，而发布出去的 ServerArgs 实例保持启动原样
self.assertEqual(get_memory().hicache_storage_backend, "file")
self.assertEqual(
    get_context().resolved_server_args_dict()["hicache_storage_backend"],
    "file",
)
self.assertIsNone(self.server_args.hicache_storage_backend)

```

评论区精华

本 PR 自身无 review 评论 (review_comments_count: 0)，讨论均发生在前身 #33240 上，PR body 明确「The review discussion and the triage of each round of comments is on #33240; the code here is identical to that PR's final revision」。核心要点：① GitHub 将 chained-base 系列视为 stack，阻塞 base retargeting 与除异步端点外的所有合并路径，因此弃用 #33240、基于 main 重提；② 配置归属边界——调度器侧写进程级 bags、tokenizer 侧留 per-engine manager，`runtime_context.py` docstring 明确「The two are separate logs, not one merged dict」，两套日志刻意不合一；③ 守卫测试必要性——直读 `ServerArgs` 的失败模式是静默过期读回，不报错只返回旧值，故用枚举模块 + 正则扫描钉死 7 个 readback 模块，Prometheus label 集合因须与序列同生命周期而豁免；④ 验证空白——HiCache attach/detach over HTTP 需带分层缓存的真实服务，作者明言未在本端到端验证。Issue 上仅有一条 Gemini Code Assist 停服的机器人通知，无实质内容。

- chained-base 系列被 GitHub 视为 stack 导致合并阻塞 (other): 弃用 #33240，本 PR 基于 main 重提，代码与其最终版一致。
- 进程级 bags 与 per-engine manager 的配置归属边界 (design): 两套日志刻意不合一，防止多 Engine 共享 tokenizer 进程时串扰。
- 守卫测试防止静默过期读回回潮 (testing): 新增 `TestControlPlaneFieldsAreNotReadFromTheInstance`，扫描 7 个 readback 模块中的 8 个控制面字段。
- HiCache attach/detach HTTP 路径末端到端验证 (testing): 依赖单元测试覆盖逻辑路径，端到端验证留待后续；已标注为已知验证空白。

风险与影响

- 风险：
 - 静默过期读回（主要回归面）：外部消费者（监控工具、KV-aware 路由、依赖 `/get_server_info` 的旧客户端）依赖读回字段的即时性。守卫测试只覆盖 `READBACK_MODULES` 内 7 个模块，未来新增读回模块若直读 `self.server_args.<控制面字段>`，不会被现行正则捕获，`EXEMPT_LINES` 也会留出口子。

- 多 Engine 并发叠加：_config_updates 是单一列表，同进程多 Engine 的更新按追加顺序后写覆盖；若两引擎并发更新同一字段，读出为最后写入者，符合 per-manager 语义但需业务侧确认可接受。
- 崩溃转储降级：_dump_config_snapshot 遇不可序列化配置返回 None，转储会缺失 resolved config 但保留请求数据；回退同时置空两个字段的已有测试覆盖。
- 端到端验证空白：HiCache HTTP attach/detach 路径未在本地验证，属于已知风险，依赖单测覆盖逻辑路径。
- 影响：影响范围集中在控制面与可观测性层：所有 introspection 端点（HTTP /server_info、/model_info、/hicache/storage-backend, gRPC get_model_info/get_server_info, Engine.get_server_info）返回的 weight_version、model_path、HiCache 字段现在反映运行期实际生效配置；对共享 tokenizer 进程的多引擎部署是正确性修复（此前进程级 bags 下直写实例会串扰）；对外部消费者字段兼容性保持，仅语义变为「当前生效配置」。团队层面确立了「进程级 bags vs per-engine manager」的配置分层边界，为系列后续（#33338 清除全部进程级配置字段直读）铺路。
- 风险标记：readback 面广、漏改即静默过期，守卫测试依赖正则扫描存在盲区，HiCache attach HTTP 路径未端到端验证，崩溃转储配置快照可能缺失

关联脉络

- PR #33240 同系列前身 PR (chained-base 版，已关闭未合并；标题未提供)：PR body 明确本 PR 是其替代实现，代码与其最终版一致；因 GitHub stack 机制阻塞合并而关闭，全部 review 讨论都在该 PR 上。
- PR #33337 observability: publish the generated forward-pass-metrics endpoint to the bags: 同为 5 步配置梳理系列前序步骤：FPM 端点写入迁移至配置 bags，与本 PR 共享 runtime_context.override 机制与 ratchet 测试，定义了调度器侧 '写 bags' 的模式。
- PR #33338 config: retire the last process-global config field reads: 系列后续步骤：清除最后一批进程级配置字段直读并迁移至命名空间访问器，与本 PR 一脉相承，共同把 ServerArgs 收敛为 '启动记录' 语义。
- PR #33294 test: stand up the config tiers two unit tests read from: 发布真实配置修复两个 main 分支失败的单测，与 config tiers 系列同属配置分层工作，为本 PR 的测试桩升级（真实 TokenizerManager 替代 SimpleNameSpace）提供了方向。