

PR #37049 完整报告

sgl-project/sglang

[Diffusion] Make component execution options fail closed

合并时间: 2026-08-30 21:06

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/37049>

执行摘要

- 一句话: 组件执行选项 fail-closed 化, 显式配置未兑现即报错
- 推荐动作: 值得精读。最有价值的设计是 selector.py 中在 context manager 的 finally 之后抛异常的写法——先保证上下文重置与日志汇总, 再向调用方报告未兑现的显式选项; 以及 "显式 vs 自动" 的语义区分 (用户传入必须兑现, 框架推导可以豁免)。对设计运行时准入校验的团队, 这个 fail-closed 模式可以直接借鉴。

功能与动机

PR body 明确给出了共享契约: "an explicit component option must either be honored by the actual runtime path or fail before fallback/use"。此前 diffusion 运行时存在三类静默失效: native fallback 无法兑现 TP/SP/Ulysses/Ring/KV-gather/FSDP 等分布式布局、组件级 attention backend 覆盖落在不消费 SGLang attention 层的组件上、显式组件 /layerwise offload 没有请求期 ComponentUse 却从不搬运设备。这些配置此前会被接受但实际不生效, 用户难以察觉, 因此需要 fail-closed 的准入校验。

实现拆解

变更围绕 "显式选项要么被兑现、要么提前失败" 这一契约, 按四条边界落地:

1. 组件 attention backend fail-closed (selector.py + minimax_h3.py + server_args.py)
: component_attn_backend_context_manager 新增
require_component_backend_selection 参数 (默认 True), 在上下文退出时检查
selected_backends 是否为空且存在显式 backend; 若组件从未构建 SGLang attention 层, 则在上下文重置后抛出 ValueError。为避免误伤, 新增
record_component_attn_backend 供非层构造路径 (如 minimax_h3.py 中 deferred model-specific resolution) 登记选择; 同时 server_args.py 用
_automatic_component_attention_backend_keys 记录 LTX2 / MiniMax H3 自动推导的
text_encoder: torch_sdpa, 通过 is_component_attention_backend_automatic 豁免自动默认。
2. native fallback 分布式布局拒绝 (transformer_loader.py + pipeline_configs/base.py)
: validate_native_fallback 先调用 super() 走基类的 native_only_components 契约检查, 再逐项拒绝 tp_size、sp_degree、ulysses_degree、ring_degree、kv_gather_degree 大于 1 或 FSDP 请求, 在真正执行 native load 之前抛 RuntimeError。
native_only_components 从 component_loader.should_raise_customized_load_error 里

的 `getattr` 反射探测改为 `PipelineConfigBase` 上的类型化字段直接访问。

3. 显式 offload 与请求期声明绑定 (`component_manager.py`) : `begin_request` 末尾新增 `_validate_explicit_nonresident_components`, 枚举 `pipeline.modules` 中 `explicit_residency_mode` 为 `COMPONENT_OFFLOAD` / `LAYERWISE_OFFLOAD` 的模块, 若其名称未出现在各 stage 声明的 `ComponentUse` 中, 则抛 `ComponentResidencyError`, 避免 " 配置了 offload 但前向前永不被搬运 " 的静默失效。
4. 测试配套: 五个单元测试文件覆盖三条真实边界——`test_transformer_loader_fallback.py` 用 mock 验证分布式执行在 native load 前被拒绝、`replicated` 配置保留 fallback; `test_component_residency.py` 验证 offload 必须有 `ComponentUse` 声明、有声明则放行; `test_attention_backend_selector.py` 验证显式 backend 未消费 attention 层时报错、加载异常保留且上下文重置、自动 backend 可跳过检查; `test_server_args.py` 验证 LTX2 自动 backend 不算显式覆盖; `test_vae_loader.py` 验证 `native_only_components` 默认空元组。文档两处 (`cli.mdx`、`attention_backends.mdx`) 同步更新错误信息措辞。

关键文件:

- `python/sglang/multimodal_gen/runtime/layers/attention/selector.py` (模块 注意力选择; 类别 source; 类型 core-logic; 符号 `component_attn_backend_context_manager`, `record_component_attn_backend`, `_record_component_attn_backend`) : fail-closed 核心机制所在: context manager 新增 `require_component_backend_selection` 校验, 新增 `record_component_attn_backend` 供非层构造路径登记后端选择。
- `python/sglang/multimodal_gen/runtime/managers/memory_managers/component_manager.py` (模块 驻留管理; 类别 source; 类型 core-logic; 符号 `_validate_explicit_nonresident_components`, `begin_request`) : 新增 `_validate_explicit_nonresident_components`, 把显式 offload 与请求期 `ComponentUse` 声明绑定, 杜绝 " 配置了 offload 但前向前永不被搬运 " 的静默失效。
- `python/sglang/multimodal_gen/runtime/loader/component_loaders/transformer_loader.py` (模块 回退加载; 类别 source; 类型 core-logic; 符号 `validate_native_fallback`) : native fallback 准入核心: 先走基类 `native_only_components` 契约, 再拒绝 TP/SP/Ulysses/Ring/KV-gather/FSDP 布局, 新增 `kv_gather_degree` 拒绝项。
- `python/sglang/multimodal_gen/runtime/loader/component_loaders/component_loader.py` (模块 组件加载; 类别 source; 类型 core-logic; 符号 `should_raise_customized_load_error`, `_load_customized_with_context`, `_load_native_with_context`, `load_component`) : `native_only_components` 从 `getattr` 反射探测改为类型化契约直接访问; 三条加载路径统一计算 `require_component_backend_selection`。
- `python/sglang/multimodal_gen/runtime/server_args/server_args.py` (模块 服务参数; 类别 source; 类型 core-logic; 符号 `is_component_attention_backend_automatic`, `_adjust_attention_backend`) : 新增 `_automatic_component_attention_backend_keys` 与 `is_component_attention_backend_automatic`, 区分框架自动推导与用户显式覆盖的组件 backend。
- `python/sglang/multimodal_gen/configs/pipeline_configs/base.py` (模块 流水线配置; 类别 source; 类型 data-contract; 符号 `native_only_components`) : 声明

native_only_components 类型化契约字段，替代 loader 中的反射探测，是本 PR " 契约化 " 的载体。

- python/sglang/multimodal_gen/runtime/models/dits/minimax_h3.py (模块 模型实现; 类别 source; 类型 data-contract; 符号 record_component_attn_backend) : 在模型构造入口登记 deferred model-specific 的 attention backend 选择, 防止 fail-closed 检查误判为未兑现。
- python/sglang/multimodal_gen/test/unit/test_transformer_loader_fallback.py (模块 单元测试; 类别 test; 类型 test-coverage; 符号 _mocked_load, test_distributed_execution_rejects_before_native_load, test_replicated_cfg_and_dp_keep_native_fallback) : 用 mock 覆盖真实 load 边界: 分布式执行在 native load 前被拒绝、replicated 配置保留 fallback, 测试质量最高的配套文件。
- python/sglang/multimodal_gen/test/unit/test_component_residency.py (模块 单元测试; 类别 test; 类型 test-coverage; 符号 _server_args_with_component_offload, test_explicit_component_offload_requires_a_declared_request_use, test_declared_component_use_admits_explicit_component_offload) : 覆盖显式 offload 必须有请求期 ComponentUse 声明、有声明则放行的双向测试。
- python/sglang/multimodal_gen/test/unit/test_attention_backend_selector.py (模块 单元测试; 类别 test; 类型 test-coverage; 符号 test_component_override_requires_an_sglang_attention_layer, test_component_override_preserves_load_error_and_resets_context, test_automatic_component_backend_may_skip_sglang_attention_layer) : 覆盖 fail-closed 的三个关键语义: 显式 backend 未消费 attention 层报错、加载异常保留且上下文重置、自动 backend 可跳过检查。

关键符号: record_component_attn_backend, component_attn_backend_context_manager, _validate_explicit_nonresident_components, is_component_attention_backend_automatic, validate_native_fallback, should_raise_customized_load_error, _load_customized_with_context

关键源码片段

python/sglang/multimodal_gen/runtime/layers/attention/selector.py

fail-closed 核心机制所在: context manager 新增 require_component_backend_selection 校验, 新增 record_component_attn_backend 供非层构造路径登记后端选择。

```
@contextmanager
def component_attn_backend_context_manager(
    attn_backend: AttentionBackendEnum | None,
    component_name: str | None = None,
    allow_global_backend_fallback: bool = False,
    require_component_backend_selection: bool = True,
) -> Generator[None, None, None]:
    # 未指定 backend 且未指定组件名时直接透传, 不进入 fail-closed 校验。
    if attn_backend is None and component_name is None:
        yield
    return
```

```

token = component_attn_backend_context.set(
    ComponentAttnBackendContext(
        attn_backend,
        component_name,
        {},
        allow_global_backend_fallback,
    )
)
unused_component_name: str | None = None
unused_backend_name: str | None = None
completed = False
try:
    yield
    completed = True
finally:
    context = component_attn_backend_context.get()
    # 只有「显式指定 backend」且「组件从未记录任何后端选择」时才判定为未兑现。
    unused_component_override = (
        completed
        and require_component_backend_selection
        and (
            context is not None
            and context.backend is not None
            and context.component_name is not None
            and not context.selected_backends
        )
    )
    if unused_component_override:
        unused_component_name = context.component_name
        unused_backend_name = context.backend.name.lower()
        _log_component_attn_backend_summary(context)
        component_attn_backend_context.reset(token)
# 把异常推迟到上下文重置之后抛出，保证 ContextVar 先被清理、日志先被输出。
if unused_component_name is not None and unused_backend_name is not None:
    raise ValueError(
        f"Attention backend {unused_backend_name!r} was requested for component "
        f"{unused_component_name!r}, but that component "
        "did not construct an SGLang attention layer."
    )

```

python/sglang/multimodal_gen/runtime/managers/memory_managers/component_manager.py

新增 `_validate_explicit_nonresident_components`，把显式 offload 与请求期 `ComponentUse` 声明绑定，杜绝 " 配置了 offload 但前向前永不被搬运 " 的静默失效。

```

def _validate_explicit_nonresident_components(self) -> None:
    """拒绝没有请求期 use 站点的显式 offload 选择器。

```

Component placement 由请求时间线执行，而不仅是选择初始加载设备。

如果没有声明 ComponentUse, 显式 non-resident 模块会被接受, 但在前向传播之前永远不会被移动到目标设备, 从而静默失效。

```
"""
```

```
# 单元测试常用 SimpleNamespace 替代 ServerArgs, 此时跳过校验。
```

```
if not isinstance(self.server_args, ServerArgs):
```

```
    return
```

```
# 收集 pipeline 中所有 stage 声明的组件使用点。
```

```
declared_components = {use.component_name for use in self._ordered_uses}
```

```
unmanaged_components = sorted(
```

```
    component_name
```

```
    for component_name, module in self.pipeline.modules.items()
```

```
    if isinstance(module, nn.Module)
```

```
    and self.server_args.explicit_residency_mode(component_name)
```

```
    in (COMPONENT_OFFLOAD, LAYERWISE_OFFLOAD)
```

```
    and component_name not in declared_components
```

```
)
```

```
if unmanaged_components:
```

```
    names = ", ".join(repr(name) for name in unmanaged_components)
```

```
    raise ComponentResidencyError(
```

```
        "Explicit component residency requires "
```

```
        f"{names} to have a request-time ComponentUse declaration; "
```

```
        "none appears in this pipeline"
```

```
)
```

python/sglang/multimodal_gen/runtime/loader/component_loaders/transformer_loader.py

native fallback 准入核心: 先走基类 native_only_components 契约, 再拒绝

TP/SP/Ulysses/Ring/KV-gather/FSDP 布局, 新增 kv_gather_degree 拒绝项。

```
def validate_native_fallback(self, server_args: ServerArgs, component_name: str) -> None:
```

```
    # 先执行基类契约检查: pipeline_config.native_only_components 中列出的
```

```
    # 组件一律走 native 加载, 禁止自定义加载器回退。
```

```
    super().validate_native_fallback(server_args, component_name)
```

```
# 收集所有请求的分布式执行布局; 任一布局无法由 native fallback 兑现时,
```

```
# 在真正执行 native load 之前直接失败, 而不是静默忽略用户配置。
```

```
requested_distributed_execution = []
```

```
if server_args.tp_size is not None and server_args.tp_size > 1:
```

```
    requested_distributed_execution.append(f"tp_size={server_args.tp_size}")
```

```
if server_args.sp_degree is not None and server_args.sp_degree > 1:
```

```
    requested_distributed_execution.append(f"sp_degree={server_args.sp_degree}")
```

```
if server_args.ulysses_degree is not None and server_args.ulysses_degree > 1:
```

```
    requested_distributed_execution.append(
```

```
        f"ulysses_degree={server_args.ulysses_degree}"
```

```
)
```

```
if server_args.ring_degree is not None and server_args.ring_degree > 1:
```

```
    requested_distributed_execution.append(
```

```
        f"ring_degree={server_args.ring_degree}"
```

```

    )
    # kv_gather_degree 是本 PR 新增的拒绝项，与其余布局一并检查。
    if (
        server_args.kv_gather_degree is not None
        and server_args.kv_gather_degree > 1
    ):
        requested_distributed_execution.append(
            f"kv_gather_degree={server_args.kv_gather_degree}"
        )
    if server_args.should_use_fsdp_for_component(component_name):
        requested_distributed_execution.append("FSDP")
    if requested_distributed_execution:
        raise RuntimeError(
            f"Component {component_name!r} cannot honor requested distributed execution: "
            f"{'', '.join(requested_distributed_execution)}. Use an SGLang-native "
            "transformer implementation or set tp_size, sp_degree, "
            "ulysses_degree, ring_degree, and kv_gather_degree to 1 without "
            "FSDP."
        )

```

评论区精华

该 PR 没有实质 review 评论（review 评论 0 条，唯一 issue 评论是 mintlify 文档预览 bot），核心权衡体现在 commit 迭代与 PR body 中：

- 自动 backend 与显式 backend 的区分：第二个 commit fix: preserve automatic component attention defaults 表明 LTX2 / MiniMax H3 自动设置的 text_encoder: torch_sdpa 曾可能被误判为显式覆盖而触发 fail-closed。结论是显式覆盖必须失败、自动默认必须豁免，凭据是 server_args._automatic_component_attention_backend_keys。
- 无 attention 后端组件的兼容：第三个 commit fix: preserve backend-free component loader paths 表明 VAE 等不消费 SGLang attention 层的组件需要豁免路径。最终通过 require_component_backend_selection 参数显式控制，并在 attn_backend 为 None 时不触发检查。
- 四合一合并策略：body 明确说明本 PR 取代 #37041、#37044、#37045、#37046，作为唯一 NVIDIA CI 候选，减少 CI 噪音并集中审查。
 - 自动推导的组件 backend 不应触发 fail-closed (design): 显式覆盖必须 fail-closed，自动默认必须豁免；区分依据是 backend 是否由框架推导而非用户传入。
 - 无 attention 后端的组件加载路径兼容 (design): 该行为是刻意的 fail-closed；需要豁免的路径显式传入 require_component_backend_selection=False，且 attn_backend 为 None 时检查本身不触发。
 - 四个 PR 合并为单一 CI 候选 (other): 合并完成，本 PR 为最终审查单元，减少了 CI 噪音与重复审查。

风险与影响

- 风险：

- selector.py 行为 breaking change: require_component_backend_selection 默认 True, 任何注册了组件 backend 上下文但未构建 SGLang attention 层的既有路径都会从静默变为 ValueError。未来新增不消费 attention 层的组件 (如新的 VAE / 声码器) 若显式指定 backend, 必须显式传 False, 否则启动失败。
- server_args.py 新增状态易遗漏: _automatic_component_attention_backend_keys 依赖 _adjust_attention_backend 中所有自动推导点同步登记, 后续新增自动 backend 推导逻辑若忘记登记, 会把自动默认误判为显式覆盖。
- component_manager.py 校验依赖枚举完整性: _validate_explicit_nonresident_components 只检查 isinstance(module, nn.Module) 的模块, 且 isinstance(self.server_args, ServerArgs) 保护了测试用的 SimpleNamespace; 若生产路径传入代理对象会跳过校验。既有 " 为预留显存而配置 offload 但模型实际不使用该组件 " 的配置在升级后会直接报错。
- transformer_loader.py 新增拒绝项: kv_gather_degree > 1 现在与 tp/sp/ulysses/ring 一起被拒绝, 若用户环境中 KV-gather 并行与 diffusers 回退加载组合使用 (此前可能静默异常), 升级后将显式失败。
- CI 信号: PR Test (Extra) 与 AMD ROCm 7.2 运行显示失败 (:x:), 虽未说明原因, 但属于需要留意的回归信号。
- 影响: 对用户: 三处显式配置 (分布式布局、组件 attention backend、组件 offload) 从 " 接受但静默失效 " 变为 " 带明确错误信息提前失败 ", 错误信息直接指出修复方向 (如回退到 SGLang-native transformer 或关闭并行选项)。对系统: 变更集中在 diffusion 多模态生成运行时的校验路径, 不触碰计算主路径, 无新增生产模块, 启动期 / 请求期开销可忽略。对团队: 四个 PR 合并为单一 CI 候选, 审查负担降低; 但自动 backend 豁免集合成为新的维护状态, 后续所有自动 backend 推导点都需同步更新。
- 风险标记: 行为契约收紧可能影响既有配置, 自动 backend 豁免依赖新增状态集合, 跨模块校验逻辑分散在四条边界, CI Extra 与 AMD ROCm 运行失败待确认

关联脉络

- PR #37041 component-execution admission 前置 PR (被本 PR 整合): PR body 明确说明本 PR 整合 #37041 的改动。
- PR #37044 component-execution admission 前置 PR (被本 PR 整合): PR body 明确说明本 PR 整合 #37044 的改动。
- PR #37045 component-execution admission 前置 PR (被本 PR 整合): PR body 明确说明本 PR 整合 #37045 的改动。
- PR #37046 component-execution admission 前置 PR (被本 PR 整合): PR body 明确说明本 PR 整合 #37046 的改动。
- PR #36907 [Diffusion] Enforce component attention backend application: 同一 attention backend 选择子系统, 改动 selector.py、minimax_h3.py、component_loader.py、server_args.py, 与本 PR 的 fail-closed 校验同属一条功能演进线。
- PR #36991 [Diffusion] Add exact component precision overrides: 组件加载参数契约演进, 涉及 component_loader.py / server_args.py, 与本 PR 的 native_only_components 契约化方向一致。

- PR #36875 [diffusion] Preserve exact component identity during loading: 组件加载身份与一致性, 涉及 component_loader.py / transformer_loader.py, 与本 PR 的加载准入逻辑同属组件加载子系统。
- PR #36916 [Diffusion] Detect quantized transformer replacements: 涉及 transformer_loader.py 的加载探测逻辑, 与本 PR 的 native fallback 准入改动同文件同区域。