

# PR #35707 完整报告

sgl-project/sglang

[diffusion] read the cgroup this process is actually in

合并时间: 2026-08-21 08:48

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/35707>

## 执行摘要

- 一句话: 修复嵌套 cgroup 下内存上限误读, 避免 OOM
- 推荐动作: 值得精读。核心看点: 一是容器内外 cgroup 路径不对齐问题的“渐进缩短后缀”解法, 简洁、无依赖且语义清晰; 二是“取最紧 cap + 对应 usage”的选择, 正确反映了 cgroup 层级继承; 三是测试用 tmp\_path 构造嵌套 cgroup 树的方式, 值得作为同类 sysfs 探测逻辑的测试模板。建议后续补充 v2 嵌套场景用例, 并关注混合 v1/v2 挂载下的边界行为。

## 功能与动机

cgroup\_memory\_limit\_bytes 原实现固定读取 /sys/fs/cgroup/memory.max (v2) 与 /sys/fs/cgroup/memory/memory.limit\_in\_bytes (v1), 即 mount root 的上限。对直接位于该 cgroup 的进程 (普通容器) 这是正确的, 但对进程位于更深的 cgroup (systemd scope 带 MemoryMax、容器以 --cgroup-parent 启动、或任何嵌套更紧的 cgroup) 时, 读到的是父级更大的数字。pinned host memory 便按进程实际无法拥有的内存来规划——这正是该模块要防止的过度承诺——最终以 OOM kill 收场, 而不是优雅回退到 pageable 内存。PR body 明确要求从 /proc/self/cgroup 解析进程自身 cgroup 并沿链到 mount root 取最紧 cap。

## 实现拆解

1. 解析进程自身 cgroup: 在 host\_memory\_budget.py 中新增 \_own\_cgroup\_path(), 读取 \_PROC\_SELF\_CGROUP 常量 (/proc/self/cgroup), 按冒号切分为 hierarchy、controller 列表、路径三段; 优先选择 v2 行 (controller 字段为空) 或 controller 列表包含 memory 的 v1 行, 返回第三个字段; 文件读取失败或格式异常返回空串, 作为后续查找的基准。
2. 构造目录链: 新增 \_cgroup\_dirs(mount)。将 /proc 报告路径按 / 分段, 从最长后缀开始尝试 os.path.join(mount, \*parts[start:]), 用 os.path.isdir 找到第一个真实存在的目录作为叶子; 容器内外路径不对齐时 (例如 /proc 报 /docker/8e10... 而容器内 mount 下没有 docker 目录) 会自然回退到 mount 本身; 随后从叶子逐级 os.path.dirname 回溯到 mount, 得到 [leaf, ..., mount] 的目录链。
3. 取最紧 cap: 重写 cgroup\_memory\_limit\_bytes()。常量从固定文件路径 \_CGROUP\_V2/\_CGROUP\_V1 改为 \_CGROUP\_MOUNTS (v2 优先、v1 兜底的 (mount root, limit 文件名, usage 文件名) 三元组)。对每个 mount, 遍历目录链读取每层 limit, 跳过无上限 (None 或  $\geq 1 < 62$ ) 的层, 保留 limit 最小 (最紧) 的 cap 及其对应目录

的 usage。

4. 测试配套：test/unit/test\_host\_memory\_budget.py 中 \_point\_at 重构为在 tmp\_path 下构造 v2/v1 双 mount 目录树，新增 own\_path 参数模拟 /proc/self/cgroup 内容、nested 参数模拟嵌套 cgroup（按 own\_path 分段在 v1 mount 下逐级建目录）；新增 \_write\_cgroup 辅助函数；新增 TestNestedCgroup 的 4 个用例覆盖嵌套更紧、嵌套更松、路径不存在回退 mount、报告路径后缀命中四种场景。原有 TestCgroupLimit 用例适配新常量结构。
5. 无配置与部署改动；仅 2 个文件（源码 + 测试），单提交完成。

关键文件：

- python/sglang/multimodal\_gen/runtime/managers/memory\_managers/host\_memory\_budget.py（模块 内存预算；类别 source；类型 core-logic；符号 cgroup\_memory\_limit\_bytes, \_own\_cgroup\_path, \_cgroup\_dirs）：核心修复文件。重写 cgroup\_memory\_limit\_bytes 为沿目录链取最紧 cap，新增 \_own\_cgroup\_path 与 \_cgroup\_dirs 处理 /proc/self/cgroup 解析和容器内外路径对齐问题。
- python/sglang/multimodal\_gen/test/unit/test\_host\_memory\_budget.py（模块 单测配套；类别 test；类型 test-coverage；符号 \_point\_at, \_write\_cgroup, TestNestedCgroup, test\_a\_tighter\_nested\_cap\_wins\_over\_the\_root）：测试配套。\_point\_at 重构为构造 v2/v1 双目录树并支持 own\_path/nested 参数，新增 TestNestedCgroup 4 个用例覆盖嵌套 cap 竞争、路径回退与后缀命中。

关键符号：\_own\_cgroup\_path, \_cgroup\_dirs, cgroup\_memory\_limit\_bytes, \_point\_at, \_write\_cgroup, TestNestedCgroup

## 关键源码片段

python/sglang/multimodal\_gen/runtime/managers/memory\_managers/host\_memory\_budget.py

核心修复文件。重写 cgroup\_memory\_limit\_bytes 为沿目录链取最紧 cap，新增 \_own\_cgroup\_path 与 \_cgroup\_dirs 处理 /proc/self/cgroup 解析和容器内外路径对齐问题。

```
def _cgroup_dirs(mount: str) -> list[str]:
    """进程实际所在 cgroup 的目录链：从叶子逐级回溯到 mount 根。
```

核心难点：/proc/self/cgroup 报告的路径相对宿主 cgroup root，而容器内看到的 mount 已经是容器自己的 cgroup，二者不能直接拼接。实测某容器内 /proc 报 /docker/8e10...，而 /sys/fs/cgroup 下没有 docker 目录。因此从最长后缀开始探测，第一个真实存在的目录就是容器视角下的叶子，找不到则回退到 mount 本身。

```
"""
if not os.path.isdir(mount):
    return []
parts = [part for part in _own_cgroup_path().split("/") if part]
leaf = mount
for start in range(len(parts)):
    candidate = os.path.join(mount, *parts[start:])
```

```

    if os.path.isdir(candidate):
        leaf = candidate
        break
dirs = [leaf]
while dirs[-1] != mount:
    dirs.append(os.path.dirname(dirs[-1]))
return dirs

```

```

def cgroup_memory_limit_bytes() -> tuple[int, int] | None:
    """进程在其 cgroup 下的 (最紧 cap, 对应 usage), 无上限时返回 None。

```

cgroup 的 limit 沿目录链向下生效，进程实际被限制在最紧的一层；  
systemd scope 带 MemoryMax、容器以 --cgroup-parent 启动时，mount root 的数字比进程真实可用的内存大得多，按它规划 pinned host memory 就会过度承诺，最终以 OOM kill 收场而不是优雅回退到 pageable 内存。

```

"""

```

```

for mount, limit_name, usage_name in _CGROUP_MOUNTS:
    tightest = None
    for directory in _cgroup_dirs(mount):
        limit = _read_int(os.path.join(directory, limit_name))
        if limit is None or limit >= _UNLIMITED_ABOVE:
            continue # 该层无上限，不参与“最紧”比较
        if tightest is not None and limit >= tightest[0]:
            continue # 只保留更紧的 cap
        tightest = (limit, _read_int(os.path.join(directory, usage_name)) or 0)
    if tightest is not None:
        return tightest # v2 读到有效 cap 直接返回，v1 仅兜底
return None

```

## python/sglang/multimodal\_gen/test/unit/test\_host\_memory\_budget.py

测试配套。\_point\_at 重构为构造 v2/v1 双目录树并支持 own\_path/nested 参数，新增 TestNestedCgroup 4 个用例覆盖嵌套 cap 竞争、路径回退与后缀命中。

```

def _point_at(monkeypatch, tmp_path, *, v2=None, v1=None, own_path="", nested=None):
    """把 cgroup 查询重定向到 tmp_path 下的目录树。

```

own\_path 模拟 /proc/self/cgroup 报告的路径；nested 是该路径对应的 (limit, usage)，二者共同模拟“进程被挂在 mount root 之下”的嵌套场景。

```

"""

```

```

roots = {}
for key, files, values in (("v2", _V2_FILES, v2), ("v1", _V1_FILES, v1)):
    roots[key] = _write_cgroup(tmp_path / key, files, values)
if nested is not None:
    # 按 own_path 的分段在 v1 mount 下逐级创建目录，模拟容器内的
    # systemd scope 或 --cgroup-parent 形成的嵌套 cgroup
    leaf = roots["v1"]
    for part in [part for part in own_path.split("/") if part]:
        leaf = leaf / part

```

```

_write_cgroup(leaf, _V1_FILES, nested)

monkeypatch.setattr(
    host_memory_budget,
    "_CGROUP_MOUNTS",
    ((str(roots["v2"]),) + _V2_FILES, (str(roots["v1"]),) + _V1_FILES),
)
proc = tmp_path / "proc_self_cgroup"
proc.write_text(f"11:memory:{own_path}\n" if own_path else "")
monkeypatch.setattr(host_memory_budget, "_PROC_SELF_CGROUP", str(proc))

```

## 评论区精华

该 PR 无 review 评论，设计决策完全由 PR body 中的实测数据支撑：psutil 报告 2015.7 GiB 而 cgroup 上限 1117.2 GiB（900 GiB 差距）；容器内 /proc/self/cgroup 报 11:memory:/docker/8e10...，而 /sys/fs/cgroup/memory 下拼接该路径不存在。作者据此提出“渐进缩短后缀直到找到存在的目录”的算法，并承诺“无论容器如何设置都能找到叶子”。这些测量直接决定了 \_cgroup\_dirs 的回退语义，是理解实现的关键。

- 暂无高价值评论线程

## 风险与影响

- 风险：
  1. 探测依赖目录存在性：\_cgroup\_dirs 用 os.path.isdir 判断，若 cgroup 文件系统仅暴露文件不暴露目录（罕见），会回退到 mount root，行为与旧版一致，不会比改前更糟。
  2. v1/v2 混合挂载边界：\_own\_cgroup\_path 对 v1/v2 混合环境可能优先命中 v2 路径，而 v1 mount 与 v2 mount 下目录结构通常不同，v1 侧可能 miss 嵌套目录并回退 mount root；当前测试主要覆盖 v1 嵌套，v2 嵌套用例缺失。
  3. 最紧 cap 对应的 usage 取最紧层目录的 usage，cgroup usage 包含子层级，语义正确；但若最紧 cap 层与叶子层不同，usage 读数与进程实际消耗可能略有偏差，影响内存预算精度。
  4. /proc/self/cgroup 的非标准格式（多行、多控制器）可能导致路径解析不中，回退 mount root，等同旧行为，风险可控。
  5. 性能无风险：启动时读取少量小文件，对运行时无影响。- 影响：影响范围集中在 sglang.multimodal\_gen 的 host memory 预算模块：修复了 diffusion 服务在嵌套 cgroup 部署（K8s Pod 内 systemd scope、--cgroup-parent 容器等）下按错误上限规划 pinned host memory 导致 OOM kill 的问题。cgroup\_memory\_limit\_bytes 签名不变，对调用方透明；普通容器根 cgroup 场景行为不变（回退到 mount root 即旧逻辑）。对团队而言，该修复的正确性测试模式（用 tmp\_path 构造嵌套 cgroup 树 + monkeypatch /proc 路径）可复用于其他平台与后续 v2 嵌套覆盖。- 风险标记：核心路径变更（启动内存规划），cgroup 双栈兼容（v1/v2），依赖 /proc/self/cgroup 格式

## 关联脉络

- 暂无明显关联 PR