

PR #28770 完整报告

sgl-project/sglang

[MLX] Fix Apple Silicon server startup; align MLX tests with upstream

合并时间: 2026-06-24 13:58

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/28770>

执行摘要

- 一句话: 修复 MLX 后端启动崩溃并新增内存池覆盖
- 推荐动作: 值得精读的修补 PR, 展示了细粒度覆盖和契约测试的实践。建议关注 `alloc_memory_pool` 设计模式及签名验证方法。

功能与动机

PR #28660 修复了 `initialize` 参数问题, 但服务器仍因 `_init_pools` 断言失败而崩溃。根本原因是存根在 `initialize()` 中自行构建 KV 缓存池, 而基类 `alloc_memory_pool` 调用 `_init_pools` 并断言 `is_draft_worker`。通过添加无操作覆盖解决。

实现拆解

1. 源码修改: 在 `python/sglang/srt/hardware_backend/mlx/model_runner_stub.py` 的 `MlxModelRunnerStub` 类中新增 `alloc_memory_pool(self, memory_pool_config=None)` 方法, 直接返回 (无操作), 避免基类 GPU 分配。
2. 新增测试: 在 `test/registered/unit/hardware_backend/mlx/test_mlx_runner_pool_contract.py` 中添加三个契约测试, 验证覆盖存在性、无参数绑定和可选配置参数绑定。
3. 测试对齐: 修改 `test/registered/unit/hardware_backend/mlx/test_attention_patching.py`, 为 `test_finished_request_snapshots_before_release` 等测试补充上游新增的属性和存根以通过验证。

关键文件:

- `python/sglang/srt/hardware_backend/mlx/model_runner_stub.py` (模块 MLX 后端; 类别 `source`; 类型 `data-contract`; 符号 `alloc_memory_pool`): 核心变更, 新增 `alloc_memory_pool` 无操作覆盖。
- `test/registered/unit/hardware_backend/mlx/test_mlx_runner_pool_contract.py` (模块 MLX 契约测试; 类别 `test`; 类型 `test-coverage`; 符号 `TestMlxRunnerPoolContract`, `test_stub_overrides_base_alloc_memory_pool`, `test_stub_alloc_memory_pool_binds_with_no_args`, `test_stub_alloc_memory_pool_binds_with_optional_config`): 新增契约测试, 防止 `alloc_memory_pool` 覆盖丢失。
- `test/registered/unit/hardware_backend/mlx/test_attention_patching.py` (模块 注意测试调整; 类别 `test`; 类型 `test-coverage`; 符号 `fake_release_kv_cache`): 对齐上游接口变

化，确保 MLX 测试通过。

关键符号：alloc_memory_pool, test_stub_overrides_base_alloc_memory_pool,
test_stub_alloc_memory_pool_binds_with_no_args,
test_stub_alloc_memory_pool_binds_with_optional_config

关键源码片段

[python/sglang/srt/hardware_backend/mlx/model_runner_stub.py](#)

核心变更，新增 alloc_memory_pool 无操作覆盖。

```
# python/sglang/srt/hardware_backend/mlx/model_runner_stub.py
# 在 MlxModelRunnerStub 类中新增
```

```
def alloc_memory_pool(self, memory_pool_config=None):
    """No-op: MLX manages its own KV cache via MlxAttentionKVPool.

    The base ``ModelRunner.alloc_memory_pool`` runs ``_init_pools`` which asserts
    ``is_draft_worker`` (model_runner_kv_cache_mixin.py:409). Since the stub
    builds its pools eagerly in ``initialize()``, this method must short-circuit
    the GPU allocation path.
    """
    pass
```

[test/registered/unit/hardware_backend/mlx/test_mlx_runner_pool_contract.py](#)

新增契约测试，防止 alloc_memory_pool 覆盖丢失。

```
# test/registered/unit/hardware_backend/mlx/test_mlx_runner_pool_contract.py
# 新增契约测试类

import importlib.util
import inspect
import unittest

_HAS_MLX = importlib.util.find_spec("mlx") is not None

if _HAS_MLX:
    from sglang.srt.hardware_backend.mlx.model_runner_stub import MlxModelRunnerStub
    from sglang.srt.model_executor.model_runner import ModelRunner

    @unittest.skipUnless(_HAS_MLX, "requires mlx")
    class TestMlxRunnerPoolContract(unittest.TestCase):
        """``MlxModelRunnerStub.alloc_memory_pool`` must override the base."""

        def test_stub_overrides_base_alloc_memory_pool(self):
            self.assertIn("alloc_memory_pool", vars(MlxModelRunnerStub),
                          msg="MlxModelRunnerStub lost its alloc_memory_pool override.")
            self.assertIsNotNone(MlxModelRunnerStub.alloc_memory_pool,
```

```

        ModelRunner.alloc_memory_pool,
        msg="Must be overridden, not inherited.")

def test_stub_alloc_memory_pool_binds_with_no_args(self):
    sig = inspect.signature(MlxModelRunnerStub.alloc_memory_pool)
    try:
        sig.bind(object())
    except TypeError as exc:
        self.fail(f"Must accept no-arg call: {exc}")

def test_stub_alloc_memory_pool_binds_with_optional_config(self):
    # _FakeConfig is a simple stub for MemoryPoolConfig
    class _FakeConfig:
        pass
    sig = inspect.signature(MlxModelRunnerStub.alloc_memory_pool)
    try:
        sig.bind(object(), _FakeConfig())
    except TypeError as exc:
        self.fail(f"Must accept optional config argument: {exc}")

```

评论区精华

yeahdongcn 指出与 #28660 部分重复，但 Toufupi 确认 alloc_memory_pool 路径仍需修复。jlee5814 建议仅保留 alloc_memory_pool 覆盖并添加测试。最终按此方向合并。

- initialize 参数修复重复与 alloc_memory_pool 必要性 (design): 保留 alloc_memory_pool 覆盖并添加契约测试，舍弃重复的 initialize 参数更改。
- 要求添加单元测试 (testing): Toufupi 完成 rebase，保留 alloc_memory_pool 覆盖，添加单元测试并修复 test_attention_patching.py。

风险与影响

- 风险：仅影响 MLX 后端，风险较低。主要风险是未来上游重构 alloc_memory_pool 签名时覆盖可能失效，但已通过契约测试降低该风险。
- 影响：对用户：MLX 后端可正常启动；对系统：仅 MLX 路径受影响；对团队：明确了 MLX 内存池管理策略。
- 风险标记：MLX 后端变更，回归风险低，契约测试防护

关联脉络

- PR #28660 Fix MLX server startup: 修复 initialize 参数问题，是当前 PR 的前置工作。当前 PR 在此基础上新增 alloc_memory_pool 覆盖。