

PR #51120 完整报告

vllm-project/vllm

[Bugfix][Frontend] Return 400 for invalid PyNvVideoCodec video input

合并时间: 2026-08-12 18:58

原文链接: <http://prhub.com.cn/vllm-project/vllm/pull/51120>

执行摘要

- 一句话: 修复 PyNvVideoCodec 坏视频输入误报 HTTP 500, 改为返回 400
- 推荐动作: 值得精读。这是一个 "跨库异常边界翻译" 的教科书式案例: 在不改动 API 层的前提下把厂商原生异常归一化为协议错误, 并借助动态类型探测抵抗版本漂移。重点看 `_pynvvideocodec_exception_types` 的实现、两处 `try/except` 的归一化边界取舍, 以及 review 中把 mock 单测升级为真实硬件集成测试的过程——对做多模态后端或 API 错误语义的工程师有直接借鉴价值。

功能与动机

用户提供的畸形视频在多模态请求预处理时到达 `PyNvVideoCodec.SimpleDecoder`, 原生 `PyNvVCException` 此前逃逸出媒体边界, 被 API 通用异常处理器归类为 `InternalServerError`——同一请求在 NIM 公共端点与内部 vLLM 端点均返回 HTTP 500, 堆栈完全位于 `vllm/multimodal/video.py / PyNvVideoCodec` 且早于模型推理。这是客户端输入错误而非服务器故障, 应当返回 HTTP 400 而不是 500, 否则客户端无法区分输入错误与服务故障, 监控也会被用户输入污染。

实现拆解

1. 新增异常类型探测辅助函数 `_pynvvideocodec_exception_types` (`vllm/multimodal/video.py`): 动态扫描 `PyNvVideoCodec` 模块导出符号, 收集所有名字以 `PyNvVCException` 开头、是类型且继承自 `Exception` 的异常类并返回 tuple。不硬编码厂商类名, 可抵抗 `PyNvVideoCodec` 版本间的命名漂移。
2. 元数据读取边界归一化: `decode_frames_pynvvideocodec` 中包裹 `_read_source_metadata` 调用, 命中 `PyNvVCException*` 则抛出 `ValueError("Invalid or unsupported video file.")` 并保留 `cause`, 其余异常原样重抛。该路径覆盖截断 MKV、伪格式等在打开 / 扫流阶段的失败。
3. 帧解码边界归一化: `_decode_to_pinned_host` 中把 `get_decoder` 与 `get_batch_frames_by_index` 包进同一 `try/except`, 归一化范围扩大为 `PyNvVCException* + IndexError`。 `IndexError` 是 H264 实测确认的部分损坏流在批量取帧时厂商抛出的信号; 把 `get_decoder` 纳入 `try` 还使解码器槽重建失败也被归一化。
4. 不改动 API 层: vLLM 已有 `ValueError` → `BadRequestError` → HTTP 400 的映射, 本 PR 只在媒体边界做翻译, 确保 GPU 解码器不可用等服务器侧异常继续以原始状态暴露, 避免被伪装成客户端错误。

5. 测试配套: tests/multimodal/test_video.py 新增 CUDA 门控的

test_pynvvideocodec_corrupted_videos_raise_value_error, 用仓库 corrupted.mp4 资产覆盖截断打开失败、部分损坏解码失败、随后有效解码恢复三条路径;

tests/multimodal/media/test_video.py 新增 test_pynvvideocodec_unrelated_error_propagates, 用 fake nvc 模块验证无关 RuntimeError 不被归一化。

关键文件:

- vllm/multimodal/video.py (模块 视频解码; 类别 source; 类型 core-logic; 符号 _pynvvideocodec_exception_types, _decode_to_pinned_host, decode_frames_pynvvideocodec): 全部生产代码变更所在: 新增 PyNvVCException 类型探测辅助函数, 并在元数据读取与帧解码两个媒体边界做异常归一化, 是 500→400 修复的核心。
- tests/multimodal/test_video.py (模块 回归测试; 类别 test; 类型 test-coverage; 符号 test_pynvvideocodec_corrupted_videos_raise_value_error): CUDA 门控的真实 PyNvVideoCodec 集成测试, 用仓库 corrupted.mp4 覆盖截断打开失败、部分损坏解码失败与有效解码恢复三条路径, 是本次修复的主回归防线。
- tests/multimodal/media/test_video.py (模块 回归测试; 类别 test; 类型 test-coverage; 符号 test_pynvvideocodec_unrelated_error_propagates, FakePyNvVCException, raise_unrelated_error): CPU 侧回归测试, 用 fake nvc 模块 + monkeypatch 验证无关 RuntimeError 不被归一化, 锁定了异常翻译的边界, 防止未来把服务器错误误报为客户端错误。

关键符号: _pynvvideocodec_exception_types, decode_frames_pynvvideocodec, _decode_to_pinned_host, test_pynvvideocodec_corrupted_videos_raise_value_error, test_pynvvideocodec_unrelated_error_propagates

关键源码片段

vllm/multimodal/video.py

全部生产代码变更所在: 新增 PyNvVCException 类型探测辅助函数, 并在元数据读取与帧解码两个媒体边界做异常归一化, 是 500→400 修复的核心。

```
def _pynvvideocodec_exception_types(nvc) -> tuple[type[Exception], ...]:
    # 动态收集 PyNvVideoCodec 导出的所有 PyNvVCException* 异常类。
    # 不硬编码类名, 避免厂商在不同版本改名或新增子类时漏掉。
    return tuple(
        exception_type
        for name in dir(nvc)
        if name.startswith("PyNvVCException")
        and isinstance((exception_type := getattr(nvc, name)), type)
        and issubclass(exception_type, Exception)
    )

@classmethod
def _decode_to_pinned_host(
    cls,
```

```

file_path: str,
frame_idx: list[int],
nvc,
) -> npt.NDArray:
    # 帧解码边界: get_decoder 负责复用 / 重建解码器槽,
    # get_batch_frames_by_index 负责批量取帧, 两者都可能抛厂商异常。
    with cls._borrow_decoder_slot() as decoder_slot:
        stream = decoder_slot.stream
        with cls._torch_stream_context(stream):
            try:
                decoder = decoder_slot.get_decoder(
                    file_path, nvc, device_index=cls._DEVICE_INDEX
                )
                decoded_frames = decoder.get_batch_frames_by_index(frame_idx)
            except Exception as exc:
                # 只归一化厂商异常与部分损坏流特有的 IndexError,
                # 其余异常 (如 GPU 解码器不可用) 原样传播, 避免掩盖服务器故障。
                if not isinstance(
                    exc,
                    _pynvvideocodec_exception_types(nvc) + (IndexError,),
                ):
                    raise
                raise ValueError("Invalid or unsupported video file.") from exc
    # 后续帧形状校验、显存到主机拷贝逻辑保持不变……

```

```

@classmethod
def decode_frames_pynvvideocodec(
    cls,
    data: bytes,
    target: VideoTargetMetadata,
    **kwargs,
) -> tuple[npt.NDArray, VideoSourceMetadata, list[int], list[int]]:
    temp_fd, temp_path = tempfile.mkstemp(suffix=".mp4")
    try:
        with os.fdopen(temp_fd, "wb") as temp_file:
            temp_file.write(data)
        # 元数据读取边界: 截断 / 伪格式视频在此阶段抛 PyNvVCEException。
        try:
            gpu_source = cls._read_source_metadata(temp_path, nvc)
        except Exception as exc:
            if not isinstance(exc, _pynvvideocodec_exception_types(nvc)):
                raise
            raise ValueError("Invalid or unsupported video file.") from exc
        _check_frame_pixel_limit(gpu_source.width, gpu_source.height)
        # 帧采样与解码池分配逻辑保持不变……
    finally:
        with suppress(FileNotFoundError):
            os.unlink(temp_path)

```

tests/multimodal/test_video.py

CUDA 门控的真实 PyNvVideoCodec 集成测试，用仓库 corrupted.mp4 覆盖截断打开失败、部分损坏解码失败与有效解码恢复三条路径，是本次修复的主回归防线。

```
@pytest.mark.skipif(not current_platform.is_cuda(), reason="Requires CUDA")
def test_pynvvideocodec_corrupted_videos_raise_value_error():
    # 用仓库真实损坏资产覆盖两条失败路径，并用有效视频验证解码器可恢复。
    valid_video = create_long_gop_video(num_frames=2, width=64, height=64)
    corrupted_video = (ASSETS_DIR / "corrupted.mp4").read_bytes()
    malformed_video = corrupted_video[:128]

    # 记录并重置解码器槽位状态，确保测试隔离。
    old_slots = PyNvVideoCodecVideoBackend._decoder_slots
    old_active_slots = PyNvVideoCodecVideoBackend._active_decoder_slots
    old_cond = PyNvVideoCodecVideoBackend._decoder_slot_cond
    old_max_slots = PyNvVideoCodecVideoBackend._max_decoder_slots
    try:
        PyNvVideoCodecVideoBackend._decoder_slots = []
        PyNvVideoCodecVideoBackend._active_decoder_slots = 0
        PyNvVideoCodecVideoBackend._decoder_slot_cond = threading.Condition()
        PyNvVideoCodecVideoBackend._max_decoder_slots = None

        loader = VIDEO_LOADER_REGISTRY.load(PYNVVIDEOCODEC_VIDEO_BACKEND)

        # 截断文件：打开 / 元数据阶段失败，cause 为 PyNvVCEException。
        with pytest.raises(
            ValueError, match=r"^Invalid or unsupported video file\.$"
        ) as malformed_exc:
            loader.load_bytes(malformed_video, num_frames=1, hw_decoders=1)
        assert malformed_exc.value.__cause__ is not None

        # 完整损坏文件：批量解码阶段失败，cause 为厂商 IndexError。
        with pytest.raises(
            ValueError, match=r"^Invalid or unsupported video file\.$"
        ) as exc_info:
            loader.load_bytes(corrupted_video, num_frames=-1, hw_decoders=1)
        assert exc_info.value.__cause__ is not None

        # 错误后同一后端仍能成功解码有效视频，验证解码器槽未被污染。
        frames, _ = loader.load_bytes(valid_video, num_frames=1, hw_decoders=1)
        assert frames.shape[0] == 1
    finally:
        # 恢复解码器槽位状态，避免影响同进程其他测试。
        PyNvVideoCodecVideoBackend._decoder_slots = old_slots
        PyNvVideoCodecVideoBackend._active_decoder_slots = old_active_slots
        PyNvVideoCodecVideoBackend._decoder_slot_cond = old_cond
        PyNvVideoCodecVideoBackend._max_decoder_slots = old_max_slots
```

评论区精华

review 的核心交锋集中在测试策略上。Isotr0py 首轮要求用仓库真实损坏资产替代合成字节 ("Can we use the corrupted video (tests/multimodal/assets/corrupted.mp4) for test instead?")，随后澄清要的是端到端真实触发："I mean some e2e tests with corrupted video to trigger exception instead of self-contained ut with monkeypatch."。作者分三步回应：先改用 `corrupted.mp4` 资产，再新增 CUDA 门控的真实 `PyNvVideoCodec` 集成测试（覆盖损坏流映射 `ValueError` 与有效解码恢复），最终删除冗余的 `mock invalid-video` 单测，仅保留验证无关异常传播的 CPU 测试。实现决策上，归一化范围被精确限定为已导出的 `PyNvVCException*` 加部分损坏流特有的 `IndexError`，保留 `cause`，无关异常如 GPU 解码器不可用的 `RuntimeError` 必须原样传播。

- 用真实 `corrupted.mp4` 资产替代合成字节 (testing): 作者按建议改用真实资产，并进一步演进为 CUDA 门控的真实后端集成测试。
- `mock` 单测 vs 端到端真实触发 (testing): 作者新增 CUDA 门控集成测试覆盖损坏视频两条失败路径，并最终移除冗余的 `mock invalid-video` 单测，仅保留验证无关异常传播的 CPU 测试。
- 归一化边界: `PyNvVCException*` 与 `IndexError` 的取舍 (design): 边界被最终代码与测试锁定: CPU 测试验证 `RuntimeError` 不被归一化，CUDA 测试验证两侧 `ValueError` 均带 `cause`。

风险与影响

- 风险:
 1. 厂商异常命名依赖: `_pynvvideocodec_exception_types` 运行时动态探测 `dir(nvc)`，若 `PyNvVideoCodec` 新版改变异常前缀或改为非类导出，探测落空会让坏输入退回 500。已有测试锁定当前版本行为，但上游升级时需要注意。
 2. `IndexError` 匹配偏宽: `try` 块覆盖 `get_decoder + get_batch_frames_by_index` 后，任何源自这两处调用的 `IndexError` 都会被翻译为 `Invalid video`；若未来重排代码引入新的索引逻辑，可能误归一化。当前范围内可控。
 3. 解码器槽重建失败语义风险: `get_decoder` 纳入 `try` 后，解码器槽重建 / 显存分配失败也会被归一化为 400，这类失败本质可能是服务器资源问题而非输入问题。
 4. API 层回归未自动化: HTTP 400 行为仅在 B200 上手工验证，没有 API 层自动化测试，后续重构可能回归。
- 影响:
 1. API 用户: 坏视频请求响应从 500 变为 400，错误语义清晰，客户端可区分输入错误与服务故障。
 2. 监控运营: 错误日志不再因用户输入刷 `InternalServerError`，告警噪音下降。
 3. 系统改动面: 仅影响 `pynvvideocodec` 后端路径，`DeepStream`、`PyAV`、`OpenCV` 后端不受影响；解码器复用语义未变，错误后仍可继续服务有效请求（集成测试覆盖）。
 4. 团队: 为 GPU 厂商解码器的输入校验提供统一边界范例，后续可推广到其他硬件解码路径。
- 风险标记: 厂商异常类型动态探测，`IndexError` 匹配偏宽，解码器槽重建误归一

化，API 层回归未自动化

关联脉络

- PR #51139 [Bugfix][Multimodal] Invalidate retained PyNvVideoCodec decoder after failure: 同属 PyNvVideoCodec 后端错误处理系列：51139 处理失败后解码器实例状态污染，本 PR 处理输入异常语义与解码器复用路径的归一化，二者共同完善 GPU 视频解码的故障恢复。
- PR #46747 [Bugfix][V1][Multimodal] Recover from P0/P1 processor cache drift: 多模态路径从崩溃 /500 转向可恢复、语义正确的错误处理，与本 PR 的 500→400 归一化属于同一演进方向。