

PR #34892 完整报告

sgl-project/sglang

feat: add safeguards for remote media URLs

合并时间: 2026-08-15 18:12

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/34892>

执行摘要

- 一句话: 新增远程媒体 URL 域名白名单与下载大小限制, 防 SSRF
- 推荐动作: 值得精读。核心看点: 1) `download_remote_media` 中先用 `requests.Request(...).prepare().url` 统一 URL 规范化再校验, 避免解析器分歧绕过; 2) 手动逐跳重定向校验 + 流式字节上限 + 全局 `deadline` 的三重防护设计; 3) 在 `dummy-model` 边界之前通过 `server args` 发布进程级策略的接线方式。同时注意仓库正处于 `server_args` → `config bag` 迁移期, 本 PR 在 `base_processor/encode_server` 新增的直读点应在后续 `step` 迁移中纳入 `bags`。

功能与动机

PR body 明确提出: Allow deployments to restrict client-supplied remote media URLs and bound download size, 并强调 The domain allowlist remains opt-in for backward compatibility. Remote downloads default to a 64 MiB limit。SGLang 多模态入口接受客户端直接提供的 HTTP(S) 媒体 URL, 由服务端进程下载后解码; 此前既无域名限制也无大小上限, 攻击者可以诱导服务端访问内网地址或云元数据端点 (测试中明确覆盖了 `http://169.254.169.254/latest/meta-data`), 构成 SSRF, 也可以提交超大媒体耗尽内存与带宽。该 PR 以默认兼容的方式补齐这两条防线。

实现拆解

1. 新增安全下载器核心 (`python/sglang/srt/utils/common.py`): 新增 `_normalize_media_domain` (支持 IP 归一化、IDNA 域名编码、去尾点, 拒绝端口 / 路径 / URL 片段)、`configure_media_url_security` (进程级策略发布, 返回规范化域名列表)、`_assert_media_url_allowed` (域名白名单校验)、`download_remote_media` (手动跟随重定向、逐跳校验目的地、流式读取并强制字节上限与全局 `deadline`)。
2. 新增 `server` 参数与启动接线 (`python/sglang/srt/server_args.py`): 新增 `allowed_media_domains` (`List[str]`, 默认空 = 不限制) 与 `media_url_max_file_size_mb` (`int`, 默认 64, 0 表示禁用); `__post_init__` 在 `dummy-model` 边界之前调用 `_handle_media_url_security` 完成规范化并发布策略, 确保所有 `worker` 线程共享同一配置。
3. 统一 loader 接入: 公共加载器 `load_audio`、`get_image_bytes`、`_normalize_video_input` 从直连 `get_mm_http_session()` 切换到 `download_remote_media`; 模型特定处理器 `mimo_audio.preprocess_audio` (保留慢速下载告警)、`mimo_v2.has_audio_track` (放弃 `ffprobe` HTTP Range 探测, 避免绕过策略)、`mimo_v2.fetch_image`、

moss_vl._normalize_video_string（从流式写文件改为整块写入临时文件）、
inkling._resolve_media_item（urllib 替换为共享下载器）全部接入。

4. 多进程 / 分离部署发布：base_processor.BaseMultimodalProcessor.__init__ 与 disaggregation/encode_server.py 的 MMEncoder 初始化时调用 configure_media_url_security，保证 DP/ 独立编码进程也遵守同一策略。
5. 测试与文档配套：新增 test_media_url_security.py（本地 ThreadingHTTPServer 模拟同域 / 跨域重定向、声明长度与 chunked 超限、重定向循环、非法白名单条目、backslash userinfo 绕过、三个加载器共享策略）；扩展 test_server_args_migration.py（参数归一化如 Media.Example.com. → media.example.com、拒绝非法值并重置全局状态）；test_mm_process_config.py、test_kimi_k25.py、rust/qwen_fixtures.py 补充策略重置；docs 记录新参数语义。

关键文件：

- python/sglang/srt/utils/common.py（模块 工具层；类别 source；类型 core-logic；符号 _normalize_media_domain, configure_media_url_security, _assert_media_url_allowed, download_remote_media）：安全策略核心实现：新增域名白名单、重定向校验、流式下载大小限制的统一下载器，所有媒体加载路径的最终汇聚点。
- test/registered/unit/multimodal/test_media_url_security.py（模块 安全测试；类别 test；类型 test-coverage；符号 _MediaHandler, do_GET, log_message, TestMediaURLSecurity）：新增的安全回归测试文件，用本地 HTTP 服务器覆盖白名单、重定向校验、大小限制、绕过攻击等全部核心场景，是验证安全策略的关键配套。
- python/sglang/srt/server_args.py（模块 参数配置；类别 source；类型 core-logic；符号 _handle_media_url_security）：新增两个安全相关 server 参数并在启动早期发布策略，是部署方启用 / 配置安全能力的入口。
- test/registered/unit/test_server_args_migration.py（模块 参数测试；类别 test；类型 test-coverage；符号 test_media_url_security_args, test_media_url_security_args_reject_invalid_values）：验证新参数通过 A[T, Arg] 注解自动生成 CLI 参数、域名归一化（IDNA/ 去尾点 /IP）与非法值拒绝。
- python/sglang/srt/multimodal/processors/mimo_audio.py（模块 音频处理；类别 source；类型 core-logic；符号 preprocess_audio）：模型特定音频下载路径接入共享安全下载器，保留慢速下载告警逻辑。
- python/sglang/srt/multimodal/processors/mimo_v2.py（模块 多模态处理；类别 source；类型 dependency-wiring；符号 has_audio_track, fetch_image）：has_audio_track 放弃 ffprobe HTTP Range 探测（避免绕过策略），fetch_image 改用共享下载器，是消除旁路路径的关键改动。
- python/sglang/srt/multimodal/processors/base_processor.py（模块 处理器基类；类别 source；类型 core-logic）：多模态处理器初始化时发布媒体 URL 安全策略，保证 processor worker 线程共享同一策略。
- python/sglang/srt/disaggregation/encode_server.py（模块 编码服务；类别 source；类型 core-logic）：独立 MMEncoder 进程初始化时发布媒体 URL 安全策略，覆盖 PD 分离部署场景。

- docs/docs/advanced_features/server_arguments.mdx（模块 参数文档；类别 docs；类型 documentation）：记录新参数的语义、默认值与禁用方式，是部署方启用安全能力的文档入口。

关键符号：download_remote_media, configure_media_url_security, _normalize_media_domain, _assert_media_url_allowed, _handle_media_url_security

关键源码片段

python/sclang/srt/utils/common.py

安全策略核心实现：新增域名白名单、重定向校验、流式下载大小限制的统一下载器，所有媒体加载路径的最终汇聚点。

```
def download_remote_media(url: str, timeout: float) -> bytes:
    """按统一媒体 URL 策略下载一个 HTTP(S) 媒体对象。

    重定向被手动跟随，确保每个目标地址在建立连接前都先通过白名单校验；
    响应体以流式读取，在保证总请求截止时间的同时强制执行字节数上限，
    避免先将攻击者可控的响应体整体缓冲进内存。
    """

    if timeout <= 0:
        raise ValueError("media URL timeout must be positive")

    session = get_mm_http_session() # 复用 per-thread 连接池
    deadline = time.monotonic() + timeout
    current_url = url

    for redirect_count in range(_MAX_MEDIA_URL_REDIRECTS + 1):
        # 用 requests 的 prepare 逻辑做与 urllib3 一致的 URL 规范化后再校验，
        # 避免反斜杠、userinfo 分隔符等解析器不一致导致的绕过。
        prepared_url = requests.Request("GET", current_url).prepare().url
        if prepared_url is None:
            raise ValueError(f"Invalid media URL: {current_url!r}")
        _assert_media_url_allowed(prepared_url)

        remaining = deadline - time.monotonic()
        if remaining <= 0:
            raise requests.exceptions.Timeout(
                f"Timed out while downloading media URL: {url}"
            )

        with session.get(
            prepared_url,
            allow_redirects=False, # 关闭自动跟随，逐跳校验
            stream=True,
            timeout=remaining,
        ) as response:
            location = response.headers.get("Location")
            if response.status_code in _MEDIA_URL_REDIRECT_STATUS_CODES and location:
```

```

if redirect_count == _MAX_MEDIA_URL_REDIRECTS:
    raise requests.exceptions.TooManyRedirects(
        f"Media URL exceeded {_MAX_MEDIA_URL_REDIRECTS} redirects: {url}"
    )
current_url = urljoin(response.url, location)
continue

response.raise_for_status()
max_bytes = _media_url_max_file_size_bytes
# 声明长度超限的响应直接拒绝, 不必等待正文
content_length = response.headers.get("Content-Length")
if max_bytes and content_length is not None:
    try:
        declared_size = int(content_length)
    except ValueError:
        declared_size = None
    if declared_size is not None and declared_size > max_bytes:
        raise ValueError(
            f"Remote media exceeds the {max_bytes} byte download limit"
        )

content = bytearray()
for chunk in response.iter_content(chunk_size=64 * 1024):
    if not chunk:
        continue
    if time.monotonic() > deadline:
        raise requests.exceptions.Timeout(
            f"Timed out while downloading media URL: {url}"
        )
    if max_bytes and len(content) + len(chunk) > max_bytes:
        raise ValueError(
            f"Remote media exceeds the {max_bytes} byte download limit"
        )
    content.extend(chunk)
return bytes(content)

raise AssertionError("unreachable")

```

test/registered/unit/multimodal/test_media_url_security.py

新增的安全回归测试文件，用本地 HTTP 服务器覆盖白名单、重定向校验、大小限制、绕过攻击等全部核心场景，是验证安全策略的关键配套。

```

class _MediaHandler(http.server.BaseHTTPRequestHandler):
    """本地测试用 HTTP 服务，模拟可被安全策略触发的各种响应。"""

    def do_GET(self):
        if self.path == "/other-host-redirect":
            # 302 跳到另一个 host: 应被域名白名单拦截，且目标不能被访问
            self.send_response(302)

```

```

        self.send_header(
            "Location",
            f"http://localhost:{self.server.server_port}/redirect-target",
        )
        self.end_headers()
        return

    if self.path == "/chunked-oversized":
        # 不声明 Content-Length, 靠流式读取触发大小上限
        self.send_response(200)
        self.end_headers()
        self.wfile.write(b"x" * (1024 * 1024 + 1))
        return

    if self.path == "/redirect-loop":
        self.send_response(302)
        self.send_header("Location", "/redirect-loop")
        self.end_headers()
        return

    self.send_response(404)
    self.end_headers()

def log_message(self, *_):
    pass # 静默访问日志, 避免 CI 输出噪音

class TestMediaURLSecurity(unittest.TestCase):
    def test_redirect_destination_is_checked_before_fetch(self):
        # 白名单只放行 127.0.0.1, 跨域重定向应在校验阶段就被拒绝
        configure_media_url_security(["127.0.0.1"], max_file_size_mb=64)
        with self.assertRaisesRegex(ValueError, "not allowed"):
            download_remote_media(self._url("/other-host-redirect"), timeout=5)
        self.assertFalse(self.server.redirect_target_reached)

    def test_streamed_oversized_response_is_rejected(self):
        # 没有声明长度时, 流式累计超过上限也必须被拒绝
        configure_media_url_security(["127.0.0.1"], max_file_size_mb=1)
        with self.assertRaisesRegex(ValueError, "download limit"):
            download_remote_media(self._url("/chunked-oversized"), timeout=5)

```

python/sclang/srt/server_args.py

新增两个安全相关 server 参数并在启动早期发布策略, 是部署方启用 / 配置安全能力的入口。

```

allowed_media_domains: A[
    List[str],
    "Restrict client-supplied HTTP(S) image, video, and audio URLs to these "
    "exact hostnames. Redirect destinations are checked against the same "
    "allowlist. When unset, remote media from any domain is allowed.",

```

```

        NS("mm"),
    ] = dataclasses.field(default_factory=list)
    media_url_max_file_size_mb: A[
        int,
        "Maximum size in MiB for one client-supplied remote media download. "
        "The limit is enforced while streaming; set to 0 to disable it.",
        NS("mm"),
    ] = 64

def _handle_media_url_security(self):
    """Normalize and publish the media URL policy before workers start."""
    # 在 dummy-model 边界之前发布，让所有 worker 共享同一策略；
    # 默认 64 MiB，0 表示禁用大小限制。
    self.allowed_media_domains = configure_media_url_security(
        self.allowed_media_domains,
        self.media_url_max_file_size_mb,
    )

```

评论区精华

本 PR 的 `review_comments_count` 为 0，PR 评论区没有实质设计争论，主要由作者发起的 3 轮 `/rerun-test` 指令与机器人执行结果构成（覆盖 `test_media_url_security.py`、`test_server_args_migration.py`、`test_base_processor_bad_input.py`、`test_mm_process_config.py`、`test_kimi_k25.py`、rust/qwen e2e parity 等），最终全绿后无异议合并。3 次 commit 的演进顺序（功能实现 → 直接读取 server args → 更新测试 fixtures）说明作者是先完成核心逻辑，再简化参数访问方式，最后补齐测试配套。

- CI 回归验证 (other): 三轮 rerun 全部通过，PR 无 review 评论即合并；说明变更未破坏既有多模态链路。

风险与影响

- 风险：

1. DNS 重绑定 (TOCTOU) 未被覆盖：_assert_media_url_allowed 校验的是主机名字符串而非解析后的 IP，域名解析与连接建立之间若 DNS 变化仍可绕过；窗口极小且测试未覆盖，属于已知盲区。
2. 默认行为变化：media_url_max_file_size_mb 默认 64 MiB，此前远程下载无大小限制，超大媒体（如 > 64 MiB 视频）的部署会开始失败，属于静默行为变更；mimo_v2.has_audio_track 从 ffprobe Range 探测改为整体下载，任何超过限制的视频 URL 的音频探测都会被拒绝。
3. 进程级全局状态：configure_media_url_security 修改模块级全局变量，ServerArgs.__post_init__、base_processor.py、encode_server.py 多处调用；同一进程内多 engine 配置并存时会互相覆盖，与 #34376 修复的 per-runner 配置污染模式类似，测试均通过 try/finally 重置全局状态来缓解。
4. 下载路径回归面：moss_vl.py 从流式写文件改为整块内容写临时文件，inkling.py 从 urllib.request 改为 requests 下载（UA、连接复用等行为有细微差异）；受 64 MiB 上

限约束，内存风险可控，但涉及 4 个模型特定处理器的行为变化。

5. 未开启白名单时的防护缺口：白名单默认关闭时，SSRF 防护实际不生效，只剩大小限制；文档需明确提醒部署方主动开启。 - 影响：对部署方：新增 `--allowed-media-domains` 与 `--media-url-max-file-size-mb` 两个可选参数，白名单 `opt-in`、默认兼容旧行为，但 64 MiB 默认上限会约束此前无限制的超大媒体下载。对系统：公共 loader 与 4 个模型特定 processor、encode server、base processor 统一走安全下载器，消除了 `requests/urllib/ffprobe` 多套 HTTP 路径，安全策略可集中演进。对团队：建立了可复用的媒体 URL 安全基线与本地 HTTP 测试基础设施（可扩展模拟更多攻击场景）；影响范围覆盖所有接收远程多媒体 URL 的多模态服务部署，主要在数据处理链路而非推理路径。 - 风险标记：默认 `opt-in` 白名单，全局配置状态，下载路径行为变更，DNS 重绑定未覆盖，64 MiB 默认限制

关联脉络

- PR #34913 [CI] Move the static ratchets back to CPU unit tests: 与本 PR 共享 `test_server_args_migration.py` 及 `server_args` 静态 ratchet 机制；本 PR 在 `server_args.py` 新增参数后需继续满足 `global_config_read / mutation ratchet` 约束。
- PR #34819 config: the post-publish consumers of the supplied-instance surface read the bags: 仓库正推进 `server_args` 直读迁移到 config bags；本 PR 在 `base_processor.py / encode_server.py` 直接读取 `server_args` 并发布策略，属于后续迁移需覆盖的新消费点。
- PR #34376 [Fix] Make the linear-attn kernel choice per-runner, and pin draft/target loader-hook parity: `configure_media_url_security` 是进程级全局状态，与 #34376 修复的 per-runner 配置污染模式相似，可借鉴其隔离与测试思路。