

PR #29342 完整报告

sgl-project/sglang

Add native Exa-backed web_search support

合并时间: 2026-06-27 21:41

原文链接: <http://prhub.com.cn/sgl-project/sglang/pull/29342>

执行摘要

本 PR 为 SGLang Responses API 添加了原生的 Exa 网络搜索支持。通过新增 ExaClient 模块和重构 HarmonyBrowserTool，用户只需设置 EXA_API_KEY 环境变量即可使用 web_search 工具，无需额外配置 MCP 工具服务器。PR 包含完整的客户端实现、测试覆盖和文档更新，影响力中等，是 Responses 功能的重要扩展。

功能与动机

PR 正文指出: 'Adds native web_search support for GPT-OSS/SGLang Responses workflows, backed by Exa when EXA_API_KEY is configured on the SGLang server.' 主要动机是提供提供者无关的 web_search 接口，用 Exa 作为原生后端，降低用户配置成本，同时保持 MCP 扩展路径的兼容性。

实现拆解

1. Exa 客户端模块(`python/sglang/srt/entrypoints/search/exa_client.py`): 新建 ExaClient 类，依赖 aiohttp 和 msgspec，封装了搜索 (/search) 和内容获取 (/contents) 两个 API 端点；配置通过 ExaSearchConfig 控制，支持环境变量读取和边界验证。
2. 浏览器工具重写(`python/sglang/srt/entrypoints/tool.py`): HarmonyBrowserTool 不再依赖 gpt_oss，改为直接拥有 ExaClient 实例；新增 _dispatch_browser_call 方法解析 browser.search / browser.open / browser.find 动作；通过 _browser_state 维护页面状态以支持后续操作。
3. 工具服务器扩展(`python/sglang/srt/entrypoints/openai/tool_server.py`): 新增 NativeToolServer 类继承 DemoToolServer，关闭 Python 工具，仅暴露浏览器工具；在 DemoToolServer 中添加 aclose 方法以确保 ExaClient 会话关闭。
4. HTTP 服务器集成(`python/sglang/srt/entrypoints/http_server.py`): 在 lifespan 函数中根据 EXA_API_KEY 条件初始化 NativeToolServer，替代外部 MCP 工具服务器；在 finally 块中调用 aclose 进行清理。
5. 环境变量注册(`python/sglang/srt/envron.py`): 为 EXA_API_KEY、SGLANG_EXA_NUM_RESULTS、SGLANG_EXA_SEARCH_TYPE、SGLANG_EXA_INCLUDE_HIGHLIGHTS 添加 envs 描述符，支持类型解析和默认值。
6. 错误检查(`python/sglang/srt/entrypoints/openai/serving_responses.py`): 当请求包含 web_search 或 web_search_preview 工具但 supports_browsing 为 False 时，返回 400 错误和配置引导。

7. 测试覆盖([test/registered/unit/entrypoints/openai/test_exa_search.py](#)): 单元测试验证头部、负载构建、环境配置读取; 集成测试验证无网络时的错误路径。
8. 文档更新([docs_new/cookbook/...](#)): 更新 GPT-OSS cookbook 中的 web_search 配置说明。

ExaClient 核心实现 ([python/sglang/srt/entrypoints/search/exa_client.py](#))

```
import asyncio
from typing import Any, Optional
import aiohttp
import msgspec
from sglang.srt.environ import envs
from sglang.srt.utils import print_warning_once

class ExaClient:
    def __init__(self, api_key: str, *, config: Optional[ExaSearchConfig] = None, base_url: str =
        "https://api.exa.ai", timeout: float = 30.0):
        self.api_key = api_key
        self.config = config or ExaSearchConfig()
        self.base_url = base_url.rstrip("/")
        self.timeout = timeout
        self._session: Optional[aiohttp.ClientSession] = None
        self._session_lock = asyncio.Lock()

    def _headers(self) -> dict[str, str]:
        return {
            "x-api-key": self.api_key,
            "Content-Type": "application/json",
            "x-exa-integration": "sglang",
        }

    def _search_payload(self, query: str) -> dict[str, Any]:
        payload = {"query": query, "numResults": self.config.num_results, "type": self.config.
            search_type}
        if self.config.include_highlights:
            payload["contents"] = {"highlights": True}
        return payload

    def _contents_payload(self, urls: list[str]) -> dict[str, Any]:
        payload = {"urls": urls, "text": True}
        if self.config.include_highlights:
            payload["highlights"] = True
        return payload

    async def search(self, query: str) -> dict[str, Any]:
        return await self._post("/search", self._search_payload(query))

    async def contents(self, urls: list[str]) -> dict[str, Any]:
        return await self._post("/contents", self._contents_payload(urls))
```

```

async def _get_session(self) -> aiohttp.ClientSession:
    if self._session is None:
        async with self._session_lock:
            if self._session is None:
                self._session = aiohttp.ClientSession(timeout=aiohttp.ClientTimeout(total=self.
                    timeout))
            return self._session

async def close(self):
    if self._session is not None:
        await self._session.close()
        self._session = None

async def _post(self, path: str, payload: dict[str, Any]) -> dict[str, Any]:
    session = await self._get_session()
    url = f"{self.base_url}{path}"
    async with session.post(url, json=payload, headers=self._headers()) as response:
        response_text = await response.text()
        if response.status >= 400:
            raise ExaClientError(f"Exa API 请求失败, 状态码 {response.status}: {response_text}")
        try:
            return await response.json()
        except Exception as exc:
            raise ExaClientError(f"解析 Exa API 响应失败: {exc}")

```

HarmonyBrowserTool 重构 (python/sclang/srt/entrypoints/tool.py)

```

import orjson
from sclang.srt.entrypoints.search.exa_client import ExaClient, ExaSearchConfig
from sclang.srt.envron import envs
from sclang.srt.utils import print_info_once, print_warning_once

class HarmonyBrowserTool(Tool):
    def __init__(self, client: ExaClient | None = None):
        self.enabled = True
        if client is not None:
            self.exa_client = client
            print_info_once("Browser tool initialized")
            return
        api_key = envs.EXA_API_KEY.get()
        if not api_key:
            self.enabled = False
            print_warning_once("EXA_API_KEY is not set, browsing is disabled")
            return
        self.exa_client = ExaClient(api_key, config=ExaSearchConfig.from_env())
        print_info_once("Browser tool initialized")

    async def _dispatch_browser_call(self, context: ConversationContext, recipient: str, args:
        dict[str, Any]) -> str:
        if recipient == "browser.search":

```

```
query = args.get("query")
if not query:
    raise ValueError("browser.search requires a query")
data = await self.exa_client.search(query)
return self._format_search_results(context, query, data)
if recipient == "browser.open":
    url = self._resolve_url(context, args)
    data = await self.exa_client.contents([url])
    return self._format_page_contents(context, url, data)
if recipient == "browser.find":
    pattern = args.get("pattern")
    if not pattern:
        raise ValueError("browser.find requires a pattern")
    return await self._find_pattern(context, args, pattern)
raise ValueError(f"Unknown browser action: {recipient}")
```

评论区精华

本 PR 无实质性技术讨论。合并者 JustinTong0323 在 CI 失败后多次触发 `/rerun-failed-ci`，最终批准合并。Issue 评论仅有 Gemini 配额提示和 CI 命令。

风险与影响

风险：

- 新引入 aiohttp 和 msgspec 依赖，可能与其他模块产生版本冲突。
- Exa 外部 API 的可用性直接影响 web_search 功能，但错误路径会返回清晰提示。
- 环境变量配置错误时静默回退默认值（有警告但可能被忽略）。
- NativeToolServer 关闭依赖正确的生命周期管理，若 aclose 未被调用可能导致资源泄漏。

影响：

- 用户需要设置 EXA_API_KEY 才能使用 web_search；现有 MCP 工具服务器用户不受影响。
- 影响范围限于 Responses API 的 web_search 路径，不涉及核心推理流程。
- 为 SGLang 增加了原生第三方 API 集成范例，便于后续添加其他后端。

关联脉络

本 PR 是 SGLang Responses API 工具系统的重要扩展，与此前新增的 `ResponsesNativeWebSearchTestCase` (PR #29342 自身) 形成完整实现。没有发现与近期其他历史 PR 的直接关联。未来可能进一步支持其他搜索后端（如 Bing、Google）或添加更多原生工具。