

pyppeteer 的基本使用

作者: [kanadeblisst](#)

原文链接: <https://ld246.com/article/1566221786951>

来源网站: [链滴](#)

许可协议: [署名-相同方式共享 4.0 国际 \(CC BY-SA 4.0\)](#)

前言

前段时间因为任务，需要四个电商(京东、淘宝、天猫、拼多多)的数据。而其中京东的没什么爬，基本是随便抓。拼多多的加密参数有点复杂，而且变化也挺频繁的，用的是 selenium，也没什么可提的。抓淘宝和天猫因为用 selenium 滑块过不了，于是就改成了 pyppeteer。现在我说一下使用心得。有些细节因为当时没有记录，现在也记不起来了。

首先 `pip install pyppeteer`，这时候我们先看一下 websockets 这个库的版本因为必须保证这个库是 7.0 的版本。8.0 和 6.0 虽然可以使用，但是在访问多个网页会出现一些无法解决的异常。现在安装 pyppeteer，websockets 的版本默认是 8.0，我们需要先 `pip uninstall websockets` 卸载 8.0，然后 `pip install websockets==7.0`。然后我们照 <https://ld246.com/forward?goto=https%3A%2F%2Fgithub.com%2Fmiyakogi%2Fpyppeteer%2Fpull%2F160%2Ffiles> 这个网页修改 pyppeteer 的源码(如果是 anaconda，则路径 anaconda 安装路径\Lib\site-packages\pyppeteer\connection.py 这个文件)。这样准备工作就完了，这样操作之后就可以避免很多异常。

需要这么费劲的折腾，是因为 pyppeteer 这个库已经很久没有做大的更新了，虽然有点小的改，但是基本的 bug 还是没有解决。所以如果有 js 基础，最好还是使用 JavaScript 的 puppeteer 这工具，这个是谷歌出品的，一直在更新维护，基本没有 bug。

补充：有时候会出现明明网页加载完成了，但是还是会出现超时的情况。不知道是什么 bug，解决方法也很简单，只要捕获这个异常，然后该做啥做啥。

以下有的方法前面带 coroutine 这个关键字，有点没有，这是因为带这个参数的方法是异步方法，这种方法必须被 async 关键字修饰，调用的时候也必须 await 关键字修饰。不过我们虽然使用浏览器爬虫了，肯定已经不在乎效率了，异步等于在等网站封，所以只需要遵守某些规则即可(懂的请百度 asyncio 的使用)，实际上还是同步运行。另外，虽然 page.on () 这个方法是存在的，是官方文档中并未给出详细的说明，甚至我查看 pyppeteer 的源码也未找到这个函数，不知道是怎么回事。但是参考 puppeteer 的文档也是可以用的，不过报错居多，我也就没有深究了。

API 参考

启动器

`pyppeteer.launcher.launch()`

启动 chrome 进程并返回浏览器实例

参数：

`ignoreHTTPSErrors` (bool)：是否忽略 HTTPS 错误。默认为 `False`

`headless` (bool)：是否在无头模式下运行浏览器。默认为 `True` 除非 `appMode` 或 `devtools` 选项 `True`

`executablePath` (str)：运行 Chromium 或 Chrome 可执行文件的路径，不是默认捆绑的 Chromium

`slowMo` (int | float)：按指定的毫秒数减慢 pyppeteer 操作。

`args` (List [str])：传递给浏览器进程的附加参数(标志)。

`dumpio` (bool)：是否管道浏览器进程 stdout 和 stderr 进入 `process.stdout` 和 `process.stderr`。默认为 `False`。

`userDataDir` (str)：用户数据目录的路径。

`env` (dict)：指定浏览器可见的环境变量。默认与 python 进程相同。

`devtools` (bool)：是否为每个选项卡自动打开 DevTools 面板。如果是此项 `True`，`headless` 则将设置该选项 `False`。

`logLevel` (int | str)：用于打印日志的日志级别。默认值与根记录器相同。

`autoClose` (bool)：脚本完成时自动关闭浏览器进程。默认为 `True`。

- <code>loop</code> (asyncio.AbstractEventLoop) : 事件循环 (实验) 。

- <code>ignoreHTTPSErrors</code>: 意思很明显, 不解释

- <code>headless</code>: 不解释

- <code>executablePath</code>: 这个一般是默认的路径就行

- <code>slowMo</code>: 我一般会加这个参数, 至于效果吗, 好像有点。

- <code>args</code>: 常用的有['--no-sandbox','--disable-gpu','--disable-setuid-sandbox','--window-size 1440x900']

- <code>dumpio</code>: 不知道为什么, 如果不加 dumpio=True 有时会出现浏览器卡顿

- <code>userDataDir</code>: selenium 的 userdata 可以保留 cookie, 下次启动可以达到免登录, 而这个参没什么用

- <code>env</code>: 看需求

- <code>devtools</code>: 用的不深, 没用过

- <code>logLevel</code>: 没什么用, 在 Linux 下还是打印大量的日志

- <code>autoClose</code>: 默认就好, 不过如果你需要保持浏览器状态, 可以不关闭, 下次直接连接这个已存的浏览器

- <code>loop</code>: 暂时不知道有什么用

- <code>pyppeteer.launcher.connect()
连接到现有的 chrome</code>

参数: </p><code>browserWSEndpoint</code> (str) : 要连接的浏览器 websocket 端点。 (必填) <code>ignoreHTTPSErrors</code> (bool) : 是否忽略 HTTPS 错误。默认为 <code>False</code>。 <code>slowMo</code> (int | float) : 按指定的毫秒数减慢 pyppeteer 的速度。 <code>logLevel</code> (int | str) : 用于打印日志的日志级别。默认值与根记录器相同。 <code>loop</code> (asyncio.AbstractEventLoop) : 事件循环 (实验) 。 <p>browserWSEndpoint: 格式是 <code>ws://\${host}:\${port}/devtools/browser/<id></code>。以前浏览器的 wsEndpoint 这个值, 可以通过 <code>brower = pyppeteer.launcher.launch()</code> <code>dev = brower.wsEndpoint</code> 保存这个值就可以下次启动了</p><code>pyppeteer.launcher.executablePath()
获取默认 chrome 的可执行路径</code><h2 id="浏览器类">浏览器类</h2><p><code>pyppeteer.browser.Browser()
这个类是由 launch()返回的实例</code></p><code>browserContexts</code>: 返回所有打开的浏览器上下文的列表, 在新创建的浏览器中, 这将返回单个例<code>coroutine close()</code>: 关闭连接并终止浏览器进程<code>coroutine createIncognitoBrowserContext()</code>: 创建一个新的隐身浏览器上下文。这不会与其他览器上下文共享 cookie /缓存<code>coroutine disconnect()</code>: 断开浏览器

- coroutine newPage(): 在此浏览器上创建新页面并返回其对象
- coroutine pages(): 获取此浏览器的所有页面。返回格式为列表，包含所有页面
- process: 返回此浏览器的进程
- target(): 获取浏览器中所有活动目标的列表
- coroutine userAgent(): 返回浏览器的原始 UA
- coroutine version(): 获取浏览器的版本
- wsEndpoint: 返回 websocket 端点 url

<h2 id="页面类">页面类</h2>
<p>pyppeteer.page.Page()

由 browser.newPage()或者 browser.pages()得到</p>

-
<p>coroutine J(): 别名 querySelector(),看名字就知道通过 css 选择器来选出元素</p>

-
<p>coroutine JJ(): 别名 querySelectorAll()</p>

-
<p>coroutine Jeval(): 功能比 page.J()功能多一点，可以选出网页文本或者属性指</p>

-
<p>coroutine JJeval(): querySelectorAllEval()</p>

-
<p>coroutine Jx(): 别名 xpath()</p>

-
<p>coroutine addScriptTag(): 将脚本标记添加到此页面, 返回 ElementHandle

其中一个 url, path 或 content 选择是必要的。</p>

- <code>url</code> (字符串): 要添加的脚本的 URL。
- <code>path</code> (字符串): 要添加的本地 JavaScript 文件的路径。
- <code>content</code> (字符串): 要添加的 JavaScript 字符串。
- <code>type</code> (字符串): 脚本类型。使用 <code>module</code> 以加载一个 Jav Script ES6 模块。

-
<p>coroutine addStyleTag(): 将样式或链接标记添加到此页面, 返回 ElementHandle

其中一个 <code>url</code>, <code>path</code> 或 <code>content</code> 选择是必要。</p>

- <code>url</code> (字符串): 要添加的链接标记的 URL。
- <code>path</code> (字符串): 要添加的本地 CSS 文件的路径。
- <code>content</code> (字符串): 要添加的 CSS 字符串。

-
<p>coroutine authenticate(): 提供 http 身份验证的凭据</p>

-
<p>coroutine bringToFront(): 将页面置于前面</p>


```

</li>
<p>browser: 获取该页面所属的浏览器</p>
</li>
<li>
<p>coroutine click(): 相当于鼠标左键单击匹配的元素,参数是 css 选择器的字符串。如果没有匹配元素,则会引发 PageError<br>
可选参数: </p>
<ul>
<li><code>button</code> (str) : , left, right 或 middle, 默认为 left。</li>
<li><code>clickCount</code> (int) : 默认为 1。</li>
<li><code>delay</code> (int | float) : 等待时间 mousedown 和 mouseup 以毫秒为单位的间。默认为 0。</li>
</ul>
</li>
</ul>
<p><strong>注意</strong><br>
如果此方法触发导航事件并且存在单独的事件,则 waitForNavigation()最终可能会出现产生意外结的竞争条件。单击并等待导航的正确模式如下: </p>
<pre><code class="highlight-chroma"><span class="highlight-line"><span class="highlight-cl">`
</span></span><span class="highlight-line"><span class="highlight-cl">await asyncio.gat
er(
</span></span><span class="highlight-line"><span class="highlight-cl">
</span></span><span class="highlight-line"><span class="highlight-cl">    page.waitForNa
igation(waitOptions),
</span></span><span class="highlight-line"><span class="highlight-cl">
</span></span><span class="highlight-line"><span class="highlight-cl">    page.click(selec
or, clickOptions),
</span></span><span class="highlight-line"><span class="highlight-cl">
</span></span><span class="highlight-line"><span class="highlight-cl">
</span></span><span class="highlight-line"><span class="highlight-cl">
</span></span><span class="highlight-line"><span class="highlight-cl">`
</span></span></code></pre>
<p>大概意思是 click()触发如果会跳转网页,则需要 page.waitForNavigation()这个函数来等待。
点击事件和触发事件是同时的,所以需要将这两个事件绑定,代码如下。</p>
<ul>
<li>
<p>coroutine close(): 关闭此页面</p>
</li>
<li>
<p>coroutine content(): 获取页面的完整 HTML 内容</p>
</li>
<li>
<p>coroutine cookies(): 获取 cookie。参数为 URL,如果未指定 URL,则此方法返回当前页面 URL 的 cookie。如果指定了 URL,则仅返回这些 URL 的 cookie</p>
</li>
<li>
<p>coverage: 返回 coverage</p>
</li>
<li>
<p>coroutine deleteCookie(): 删除 cookie,参数为 cookie 字段参数,比如 name、url、domai
、path 等</p>
</li>
<li>
<p>coroutine emulate(): 模拟给定的设备指标和用户代理。相当于同时设置了 setUserAgent()、se

```

Viewport()

coroutine emulateMedia(): 模拟页面的 css 媒体类型。参数为：screen、print、None。

coroutine evaluate(): 在浏览器上执行 js 并获取结果

coroutine evaluateHandle(): 同上，只是会返回一个值。至于是什么，没用过

coroutine evaluateOnNewDocument(): 也是执行 js，至于区别。好像是在页面跳转时执行

coroutine exposeFunction(): 将 python 函数添加到浏览器的 window 对象中 name。不知道什么用

coroutine focus(): 聚焦匹配的元素。如果不存在，抛出 PageError

frames: 获取此页面的所有 frame

coroutine goBack(): 返回上一个网页。如果不存在，则返回 None

coroutine goForward(): 跳转到下一页。如果不存在，则返回 None

coroutine goto(): 访问某个 URL。
参数: </p>url: 。 。 。 timeout: 。 。 。 waitUntil: 什么情况下算成功访问。没看懂参数的几个值有什么用<p>coroutine hover(): 鼠标悬停匹配的元素</p><p>isClosed(): 判断页面是否关闭</p><p>keyboard: 获取 keyboard 对象</p><p>mainFrame: 获取 frame 页面的主要内容</p><p>coroutine metrics(): 好像是获取页面中的信息</p>

-
-
- <p>mouse: 获取 mouse 对象</p>
-
-
- <p>coroutine reload(): 刷新网页</p>
-
-
- <p>coroutine screenshot(): 截图

- 参数: </p>
-
- <code>path</code> (str) : 保存图像的文件路径。屏幕截图类型将从文件扩展名中推断出。
- <code>type</code> (str) : 指定屏幕截图类型, 可以是 <code>jpeg</code> 或 <code>png</code>。默认为 <code>png</code>。
- <code>quality</code> (int) : 图像的质量, 在 0-100 之间。不适用于 <code>png</code> 图像。
- <code>fullPage</code> (bool) : 如果为 true, 请截取完整的可滚动页面。默认为 <code>false</code>。
- <code>clip</code> (字典) : 指定页面剪切区域的对象。此选项应包含以下字段:
 - <code>x</code> (int) : 剪辑区域左上角的 x 坐标。
 - <code>y</code> (int) : 剪辑区域左上角的 y 坐标。
 - <code>width</code> (int) : 剪切区域的宽度。
 - <code>height</code> (int) : 剪切区域的高度。
-
-
- <code>omitBackground</code> (bool) : 隐藏默认的白色背景并允许捕获具有透明度的屏幕截图。
- <code>encoding</code> (str) : 图像的编码可以是 <code>'base64'</code> 或 <code>'binary'</code>。默认为 <code>'binary'</code>。
-
-
-
- <p>coroutine select(): 选择选项并返回所选值。如果未找到元素, 抛出 ElementHandleError。</p>
-
-
- <p>coroutine setCacheEnabled(): 为每个请求启用/禁用缓存。默认启用</p>
-
-
- <p>coroutine setContent(): 将 html 加到网页</p>
-
-
- <p>coroutine setCookie(): 设置 cookie</p>
-
-
- <p>setDefaultNavigationTimeout(): 更改默认的最大导航超时。默认 30 秒</p>
-
-
- <p>coroutine setJavaScriptEnabled(): 设置 JavaScript 启用/禁用</p>
-
-
- <p>coroutine setExtraHTTPHeaders(): 设置默认 headers 头, 值为一个字典</p>

<p>coroutine setRequestInterception(): 启用/禁用请求拦截。配合 page.on()</p>

<p>coroutine setUserAgent(): 设置要在此页面中使用的 UA</p>

<p>coroutine setViewport(): 设置窗口大小。

参数: </p>

<code>width</code> (int) : 以像素为单位的页面宽度。
<code>height</code> (int) : 以像素为单位的页面高度。
<code>deviceScaleFactor</code> (float) : 默认为 1.0。
<code>isMobile</code> (bool) : 默认为 <code>False</code>。
<code>hasTouch</code> (bool) : 默认为 <code>False</code>。
<code>isLandscape</code> (bool) : 默认为 <code>False</code>。

<p>coroutine tap(): 点击与之匹配的元素</p>

<p>coroutine title(): 获取页面标签</p>

<p>tracing: 获取 tracing 对象</p>

<p>coroutine type(): 往输入框中输入内容, 第一个参数为 css 选择器, 第二个为文本内容</p>

<p>url: 获取此页面的 url</p>

<p>waitFor(): 等待页面上匹配的函数, 超时或元素。参数可以是 int 或者 float, 单位毫秒。也可以 css 选择器</p>

<p>waitForFunction():</p>

<p>coroutine waitForNavigation(): 等到网页跳转</p>

<p>coroutine waitForRequest(): 等待请求</p>

<p>coroutine waitForResponse(): 等待回应</p>

<p>waitForSelector(): 等到页面上出现匹配的元素。其实 waitFor()也有同样功能。</p>


```

<p>waitForFunction(): 等到函数完成并返回一个值</p>
</li>
<li>
<p>coroutine waitForXPath(): 等到 xpath 页面上出现匹配的元素</p>
</li>
<li>
<p>workers: 获取页面的所有 worker。至于是什么，我不知道</p>
</li>
<li>
<p>coroutine xpath(): ..</p>
</li>
</ul>
<h2 id="worker类">worker 类</h2>
<p>page.on('workercreated', 函数) 这个函数传入的参数就是 worker 类</p>
<ul>
<li>coroutine evaluate(): 同上</li>
<li>coroutine evaluateHandle():同上</li>
<li>coroutine executionContext():同上</li>
<li>url: 同上</li>
</ul>
<h2 id="键盘类">键盘类</h2>
<ul>
<li>coroutine down(): 如果没有参数，则是按下鼠标左键。如果是键盘的某个值比如 shift、A 等键则是相当于按下这些键。</li>
<li>coroutine press(): 同 down(), 但是上面是不会释放鼠标或者键盘，需要调用 up 方法释放鼠标</li>
<li>coroutine sendCharacter: 将字符发送到页面。没用过</li>
<li>coroutine type(): 同上</li>
<li>coroutine up(): 释放由 down 按下的键或者鼠标</li>
</ul>
<h2 id="鼠标类">鼠标类</h2>
<ul>
<li>
<p>coroutine click(): 按下(x, y)处的按钮<br>
参数: </p>
<ul>
<li><code>button</code> (STR) : , left (左键)、right (右键) 或 middle (中键) , 默认为<code>left</code>。</li>
<li><code>clickCount</code> (int) : 默认为 1。</li>
<li><code>delay</code> (int | float) : 等待时间 <code>mousedown</code> 和 <code>mouseup</code> 以毫秒为单位的时间。默认为 0。</li>
</ul>
</li>
<li>
<p>coroutine down(): 同上</p>
</li>
<li>
<p>coroutine move(): 移动鼠标光标。</p>
</li>
<li>
<p>coroutine up(): 同上</p>
</li>
</ul>
<h2 id="tracing类">tracing 类</h2>

```

<p>创建可在 Chrome DevTools 或时间线查看器打开的跟踪文件，使用如下</p>

```
<pre> <code class="highlight-chroma"> <span class="highlight-line"> <span class="highlight-cl">await page.tracing.start({'path': 'trace.json'})
</span> </span> <span class="highlight-line"> <span class="highlight-cl">
</span> </span> <span class="highlight-line"> <span class="highlight-cl">await page.goto('
https://www.google.com')
</span> </span> <span class="highlight-line"> <span class="highlight-cl">
</span> </span> <span class="highlight-line"> <span class="highlight-cl">await page.tracing
stop()
</span> </span> </code> </pre>
```


coroutine start(): 开始跟踪

coroutine stop(): 停止跟踪

<p>不好用，可能是我不知道用</p>

<h2 id="Dialog类">Dialog 类</h2>

<p><code>page.on('dialog', 函数)</code>，函数的参数就是这个类</p>

coroutine accept(): 接受对话框

defaultValue: 如果对话框提示，则获取默认提示值

coroutine dismiss(): 关闭对话框

message: 获取对话框消息

type: 获取对话框类型。类型有：<code>alert</code>，<code>beforeunload</code>，<code>confirm</code>，或<code>prompt</code>

<h2 id="frame类">frame 类</h2>

coroutine J():同上

coroutine JJ():同上

coroutine JEval(): 同上

coroutine Jeval(): 同上

coroutine Jx(): 同上

coroutine addScriptTag(): 同上

coroutine addStyleTag(): 同上

childFrames: 获取子框架

coroutine click(): 同上

coroutine content(): 同上

coroutine evaluate(): 同上

coroutine evaluateHandle(): 同上

coroutine executionContext(): 同上

coroutine focus(): 同上

coroutine hover(): 同上

isDetached(): 如果此框架已分离，则返回 True

name: 获取 frame 的名称，如果没有则返回 ID

parentFrame: 获取父框架

后面这些属性和 page 类一模一样

<h2 id="ElementHandle类">ElementHandle 类</h2>

coroutine J()

coroutine JJ()

coroutine JEval()

coroutine Jeval()

asElement

- coroutine boundingBox(): 返回此元素的边界框,如果元素不可见, 则返回 None
- coroutine boxModel():返回元素框
- coroutine click()
- coroutine contentFrame(): 返回元素句柄的 frame
- coroutine focus()
- coroutine hover()
- coroutine isIntersectingViewport(): 如果元素在视口中可见, 则返回 True
- coroutine press()
- coroutine screenshot()
- coroutine tap()
- coroutine type()
- coroutine uploadFile(): 上传文件

request 类</h2>

<p>page.on('request', 函数) 这个函数传入的参数就是 request 类</p>

- coroutine abort(): 中断请求
- coroutine continue_(): 使用可选的请求覆盖继续请求

参数:

- <code>url</code> (str) : 如果设置, 请求 URL 将被更改。
- <code>method</code> (str) : 如果设置, 则更改请求方法 (例如 <code>GET</code>)
- <code>postData</code> (str) : 如果设置, 则更改发布数据或请求。
- <code>headers</code> (dict) : 如果设置, 则更改请求 HTTP 标头

- failure(): 返回错误文本
- frame : 返回匹配的 frame 对象
- headers: 返回此请求的 HTTP 标头字典
- isNavigationRequest(): ? ?
- method: 返回此请求的方法
- postData: 返回此请求的帖子正文
- redirectChain: request 类重定向的所有请求
- resourceType: 渲染引擎感知的此请求的资源类型
- coroutine respond(): 通过给定的参数修改请求

参数:

- <code>status</code> (int) : 响应状态代码, 默认为 200。
- <code>headers</code> (dict) : 可选的响应头。
- <code>contentType</code> (str) : 如果设置, 则等于设置 <code>Content-Type</code> 响应头。
- <code>body</code> (str | bytes) : 可选的响应主体。

- response(): 返回匹配的 response 对象
- url: 此请求的 URL

response 类</h2>

- buffer(): 返回相应的字节内容
- fromCache: 如果响应是从缓存提供的, 则返回 True。缓存可能是浏览器的磁盘缓存或者内存而不是服务器响应的
- fromServiceWorker: 如果响应由服务器提供, 则返回 True

- headers: 返回此响应的 HTTP 标头字典
- coroutine json(): 获取响应正文的 JSON
- ok: 返回 bool 此请求是否成功
- request: 获取匹配的 request 对象
- securityDetails: 返回与此响应关联的安全详细信息
- status: 响应的状态代码
- coroutine text(): 获取响应正文的文本
- url: 响应的 URL

<h2 id="target类">target 类</h2>
<p>我到现在还没明白这是干什么的</p>

- browser: 获取目标所属的浏览器
- browserContext: 返回目标所属的浏览器上下文
- coroutine createCDPSession(): 创建附加到目标的 Chrome Devtools 协议会话
- opener: 获取打开此目标的目标
- coroutine page(): 获取此目标的页面
- type: 获取此目标的类型
- url: 获取此目标的网址

<h2 id="CDPSession类">CDPSession 类</h2>

- coroutine detach(): 从目标分离会话
- send():

<h2 id="Debugging">Debugging</h2>
<p>对于调试, 您可以设置 for 和 功能 <code>logLevel</code> 选项。但是, 此选项会打印太多志, 包括 pyppeteer 的 SEND / RECV 消息。为了只显示被抑制的错误消息, 您应该设置 logging.DEBUG 为 True</p>
<pre><code class="highlight-chroma">import asyncio
import pyppeteer
from pyppeteer import launch

pyppeteer.DEBUG
= True # print suppressed errors as error log

async def main():

 browser = await launch()

 ... # do something

asyncio.get_event_loop().run_until_complete(main())
</code></pre>