

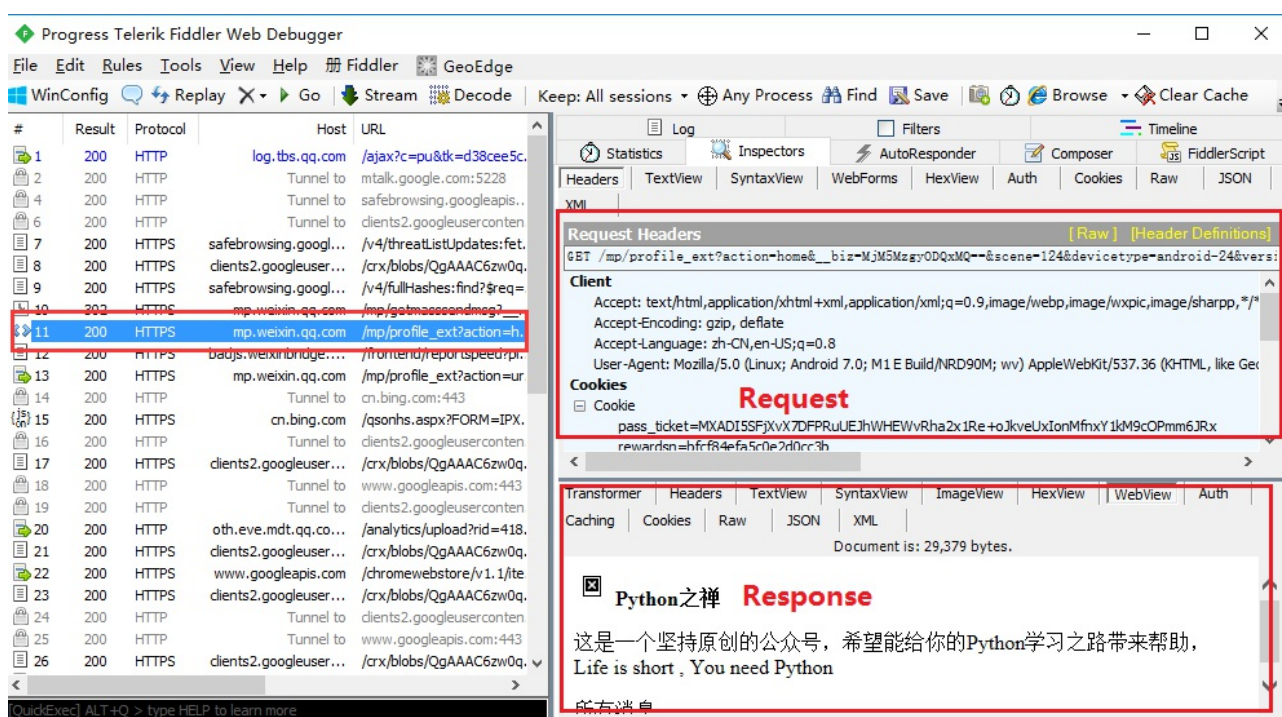
抓取第一篇微信公众号文章

上一节我们熟悉了 Fiddler 的基本操作以及每个模块所代表的意义，这节我们详细了解获取微信公众号历史文章接口的请求情况，以及如何使用 Python 模拟微信发送请求获取公众号文章的基本信息。

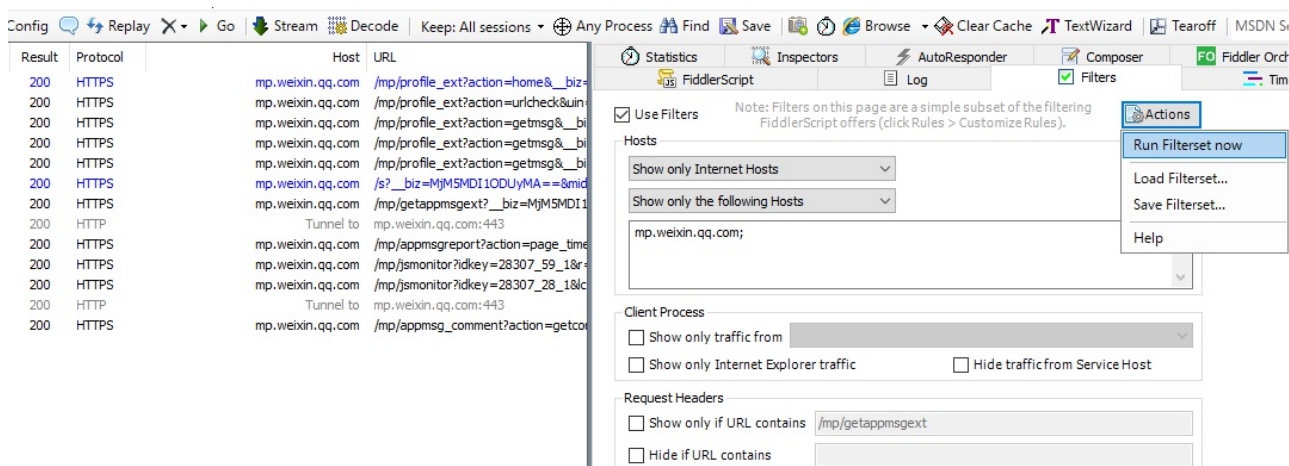
打开微信历史消息页面，我们从 Fiddler 看到了很多请求，为了找到微信历史文章的接口，我们要逐个查看 Response 返回的内容，最后发现第 11 个请求

"https://mp.weixin.qq.com/mp/profile_ext?action=home..."

就是我们要寻找的（我是怎么找到的呢？这个和你的经验有关，你可以点击逐个请求，看看返回的Response内容是不是期望的内容）



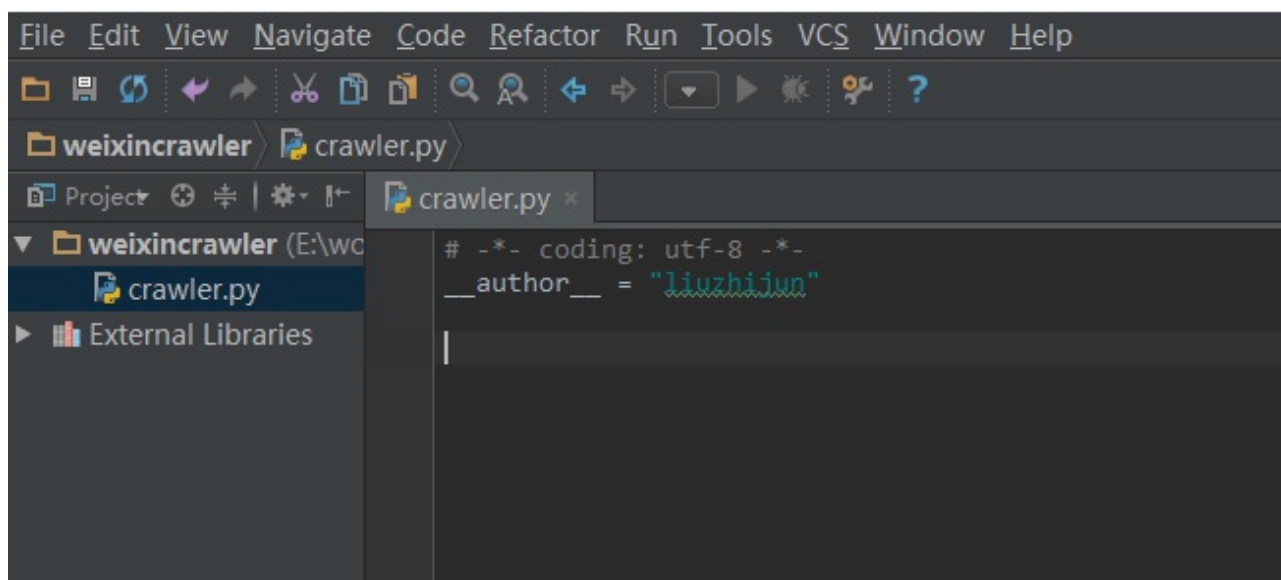
确定微信公众号的请求HOST是 mp.weixin.qq.com 之后，我们可以使用过滤器来过滤掉不相关的请求。



爬虫的基本原理就是模拟浏览器发送 HTTP 请求，然后从服务器得到响应结果，现在我们就用 Python 实现如何发送一个 HTTP 请求。这里我们使用 requests 库来发送请求。

创建一个 Pycharm 项目

我们使用 Pycharm 作为开发工具，你也可以使用其它你熟悉的工具，Python 环境是 Python3（推荐使用 Python3.6），先创建一个项目 weixincrawler

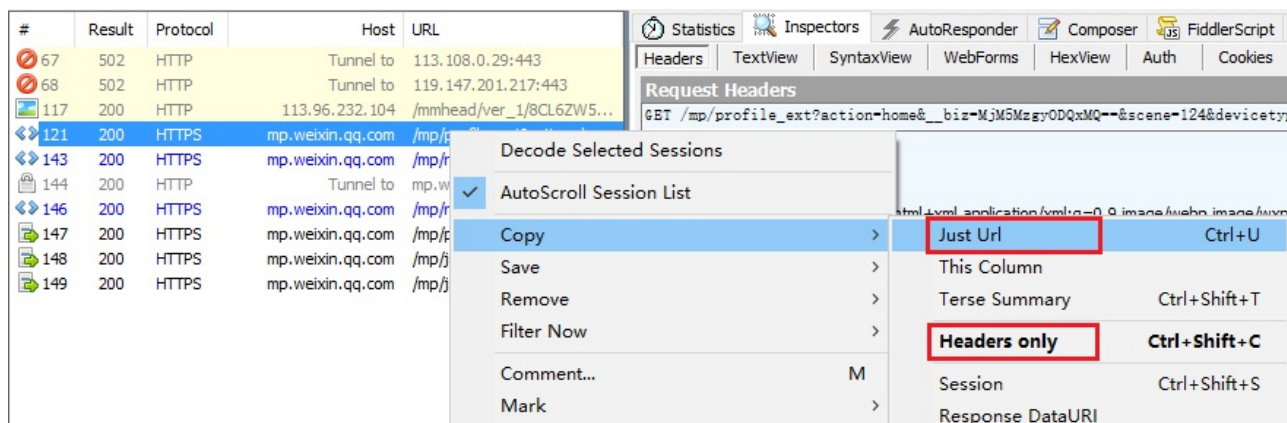


现在我们来编写一个最粗糙的版本，你需要做两件事：

- 1：找到完整URL请求地址
- 2：找到完整的请求头（headers）信息，Headers里面包括了

cookie、User-agent、Host 等信息。

我们直接从 Fiddler 请求中拷贝 URL 和 Headers，右键 -> Copy -> Just Url/Headers Only



最终拷贝出来的URL很长，它包含了很多的参数

```
url = "https://mp.weixin.qq.com/mp/profile_ext" \
      "?action=home" \
      "&__biz=MjM5MzgyODQxMQ==" \
      "&scene=124" \
      "&devicetype=android-24" \
      "&version=26051633&lang=zh_CN" \
      "&nettype=WIFI&a8scene=3" \
      "&pass_ticket=MXADI5SFjXvX7DFPRuUEJhWHEWvRha2x1Re" \
      "%2BoJkveUxIonMfnxY1kM9c0Pmm6JRx" \
      "&wx_header=1"
```

暂且不去分析（猜测）每个参数的意义，也不知道那些参数是必须的，总之我把这些参数全部提取出来。然后把 Headers 拷贝出来，发现 Fiddler 把 请求行、响应行、响应头都包括进来了，我们只需要中间的请求头部分。

因为 requests.get 方法里面的 headers 参数必须是字典对象，所以，先要写个函数把刚刚拷贝的字符串转换成字典对象。


```

def headers_to_dict(headers):
    """
    将字符串
    '''
    Host: mp.weixin.qq.com
    Connection: keep-alive
    Cache-Control: max-age=
    '''
    转换成字典对象
    {
        "Host": "mp.weixin.qq.com",
        "Connection": "keep-alive",
        "Cache-Control": "max-age="
    }
    :param headers: str
    :return: dict
    """
    headers = headers.split("\n")
    d_headers = dict()
    for h in headers:
        if h:
            k, v = h.split(":", 1)
            d_headers[k] = v.strip()
    return d_headers

```

最终 v0.1 版本出来了，不出意外的话，公众号历史文章数据就在 response.text 中。如果返回的内容非常短，而且title标签是 <title>验证</title>，那么说明你的请求参数或者请求头有误，最有可能的一种请求就是 Headers 里面的 Cookie 字段过期，从手机微信端重新发起一次请求获取最新的请求参数和请求头试试。

```
# v0.1
def crawl():
    url = "https://mp.weixin.qq.com/..." # 省略了
    headers = "" # 省略了
Host: mp.weixin.qq.com
Connection: keep-alive
Upgrade-Insecure-Requests: 1
    """
    headers = headers_to_dict(headers)
    response = requests.get(url, headers=headers,
verify=False)
    print(response.text)
```

最后，我们顺带把响应结果另存为html文件，以便后面重复使用，分析里面的内容

```
with open("weixin_history.html", "w",
encoding="utf-8") as f:
    f.write(response.text)
```

用浏览器打开 weixin_history.html 文件，查看该页面的源代码，搜索微信历史文章标题的关键字 "11月赠书"（就是我以往发的文章），你会发现，历史文章封装在叫 msgList 的数组中（实际上该数组包装在字典结构中），这是一个 Json 格式的数据，但是里面还有 html 转义字符需要处理


```

def extract_data(html_content):
    """
    从html页面中提取历史文章数据
    :param html_content 页面源代码
    :return: 历史文章列表
    """

    import re
    import html
    import json

    rex = "msgList = '({.*?})'"
    pattern = re.compile(pattern=rex, flags=re.S)
    match = pattern.search(html_content)
    if match:
        data = match.group(1)
        data = html.unescape(data)
        data = json.loads(data)
        articles = data.get("list")
        for item in articles:
            print(item)
        return articles

```

最终提取出来的数据总共有10条，就是最近发表的10条数据，我们看看每条数据返回有哪些字段。

```

article = {'app_msg_ext_info':
            {'title': '11月赠书，总共10本，附
Python书单',
            'copyright_stat': 11,
            'is_multi': 1,
            'content': '',
            'author': '刘志军',
            'subtype': 9,

```



```
        'del_flag': 1,
        'fileid': 502883895,
        'content_url':
'http:\\\\\\mp.weixin.qq.com...',
        'digest': '十一月份赠书福利如期而至,
更多惊喜等着你',
        'cover':
'http:\\\\\\mmbiz.qpic.cn\\...',
        'multi_app_msg_item_list':
[{'fileid': 861719336,

'content_url': 'http:\\\\\\mp.weixin.qq.com',
'content': '', 'copyright_stat': 11,
'cover': 'http:\\\\\\mmbiz.qpic.cn',
'del_flag': 1,
'digest': '多数情况下, 人是种短视的动物',
'source_url': '',
'title': '罗胖60秒: 诺贝尔奖设立时, 为何会被骂? ',
'author': '罗振宇'

}],
        'source_url':
'https:\\\\\\github.com\\'
    },
    'comm_msg_info': {'datetime': 1511827200,
        'status': 2,
```

```
'id': 1000000161,  
'fakeid': '2393828411',  
'content': '',  
'type': 49}}
```

我们结合下面这张图来看：

星期三 22:08

今年，谁又“暴富”了？ | 2017内容创业融资盘点

经历5年才“转正”的公众号，
2018年还有哪些可能性？



学霸时尚博主怼北京，北京真不
适合搞时尚？ | 新榜11月网红排...



这三堂课，性价比高到为商家担
心啊！ | 新榜有赚



微信“搜一搜”可以查地图了，还
能领红包；7名陌陌主播开赛，...



上面这张图是微信作为单次推送发给用户的多图文消息，有发送时间对应comm_msg_info.datetime，app_msg_ext_info中的字段信息就是第一篇文章的字段信息，分别对应：

- title：文章标题

- content_url: 文章链接
- source_url: 原文链接, 有可能为空
- digest: 摘要
- cover: 封面图
- datetime: 推送时间

后面几篇文章以列表的形式保存在 multi_app_msg_item_list 字段中。

到此, 公众号文章的基本信息就抓到了, 但也仅仅是公众号的前 10 条推送, 如何获取更多历史文章等问题放在下节讲解。

本节完整代码可以在GitHub仓库[weixincrawler_v](https://github.com/pythonzhichan/weixincrawler/tree/v0.1) (<https://github.com/pythonzhichan/weixincrawler/tree/v0.1>) 查看。