

第 5 章



IP 代理

对于采取了比较强的反爬措施网站来说,要想顺利爬取网站数据,设置随机 User-agent 和 IP 代理是非常有效的两个方法。

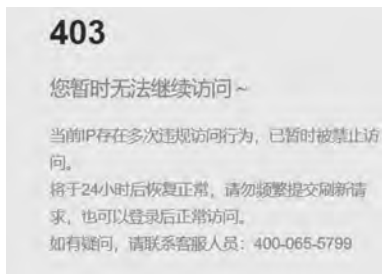


图 5.1 频繁爬取之后

代理就是换个身份,网络中的身份之一就是 IP。在爬虫中,有些网站可能为了防止爬虫或者 DDoS 等,会记录每个 IP 的访问次数。比如,有些网站允许一个 IP 在 1s 内只能访问 10 次等,那么就需要访问一次换一个 IP。如果不对 IP 做任何设置,频繁访问网站之后,网站就可能会出现图 5.1 的提示。使用 IP 代理可以解除被封 IP 这种反爬机制。

IP 代理的获取,可以从以下几个途径得到:

- (1) 从免费的网站上获取,但质量很低,能用的 IP 极少;
- (2) 购买收费的代理服务,质量高很多;
- (3) 自己搭建代理服务器,虽然稳定,但需要大量的服务器资源。

5.1 IP 代理的作用

- (1) 可以突破自身 IP 的限制,访问一些不许访问的站点;
- (2) 隐藏自身真实 IP,以免被封锁。

如果想查看本机的 IP,可以有多种方式,下面提供两种简单的查看本机 IP 的方法。

【例 5-1】 查看本机 IP。

方法 1: 在百度输入 IP 看到的就是本机 IP,如图 5.2 所示。



图 5.2 查看本机 IP

方法 2：通过程序查看,代码实现如下:

```
import requests
url = 'http://icanhazip.com'
try:
    response = requests.get(url) # 不使用代理
    print(response.status_code)
    if response.status_code == 200:
        print(response.text)
except requests.ConnectionError as e:
    print(e.args)
```

程序执行的结果如下:

```
200
123.123.40.xxx # 后三位隐去了
```

5.2 IP 代理使用方法

常见的代理包括 HTTP 代理和 SOCKS5 代理,这里主要介绍 HTTP 代理。HTTP 可以在网上搜索一些免费的 IP 代理进行测试。然后在 Requests 请求方法加入一个参数 proxies={字典}实现对 IP 代理的使用,其中字典的键名是 HTTP 或者 HTTPS,键对应的值为一个 IP 地址。

例如 proxies={'http': '59.120.117.244'},其中键名“http”表示协议类型,键值“59.120.117.244”表示代理。

如果请求 URL 使用的是 HTTP 协议,那么就使用 HTTP 代理;如果请求 URL 使用的是 HTTPS,就使用 HTTPS 代理。

【例 5-2】 设置 IP 代理爬取百度首页,代码如下:

```
import requests
url = "http://www.baidu.com/s"
headers = {
    'User-Agent': 'Mozilla/5.0 (Windows NT 10.0; Win64; x64) AppleWebKit/537.36 (KHTML, like Gecko) Chrome/86.0.4240.75 Safari/537.36'
}
response = requests.get(url = url, headers = headers, proxies = {'http': '59.120.117.244'})
with open('baidu.html', 'w', encoding = 'utf-8') as fp:
    fp.write(response.text)
```

5.3 搭建 IP 池

在爬虫过程中,使用本地 IP 频繁爬取某个网站后,可能会导致 IP 被封,因此有必要搭建一个 IP 池。


【例 5-3】 搭建一个免费的 IP 池。

【解析】 爬取快代理网站上的免费 IP,链接如下:

[“https://www.kuaidaili.com/free/”](https://www.kuaidaili.com/free/)

5.3.1 获取单页 IP

首先定义一个获取目标网页的方法,爬取目标网页如图 5.3 所示,解析出该目标页的 HTTP、PORT、IP。



IP	PORT	匿名度	类型	位置	响应速度	最后验证时间
183.195.106.118	8118	匿名名	HTTP	上海市上海市 移动	7秒	2022-01-07 06:31:01
121.13.252.61	41564	匿名名	HTTP	广东省东莞市 电信	2秒	2022-01-07 05:31:01
222.78.6.70	8083	匿名名	HTTP	中国 福建 漳州 电信	7秒	2022-01-07 04:31:01
14.215.212.37	9168	匿名名	HTTP	中国 广东 东莞 电信	4秒	2022-01-07 03:31:01
111.59.199.58	8118	匿名名	HTTP	中国 广西 百色 移动	3秒	2022-01-07 02:31:01
117.114.149.86	55443	匿名名	HTTP	北京市海淀区 BJENET宽带网络 BGP多线	0.5秒	2022-01-07 01:31:01
27.42.168.46	55481	匿名名	HTTP	中国 广东 中山 联通	2秒	2022-01-07 00:31:01
106.15.197.250	8001	匿名名	HTTP	中国 上海 联通	1秒	2022-01-06 23:31:02
47.243.68.117	8080	匿名名	HTTP	中国 香港 阿里云	1秒	2022-01-06 22:31:01
152.136.62.181	9999	匿名名	HTTP	中国	0.5秒	2022-01-06 21:31:01
152.136.62.181	9999	匿名名	HTTP	中国	0.5秒	2022-01-06 20:31:01
218.75.102.198	8000	匿名名	HTTP	浙江省金华市 电信	0.3秒	2022-01-06 19:31:01
183.247.215.216	30001	匿名名	HTTP	中国 浙江 台州 移动	0.3秒	2022-01-06 18:31:01

图 5.3 待解析的目标网页

操作步骤如下:

第一步: 查看 Network 面板,找到目标数据所在请求资源文件的 Headers,如图 5.4 所示,对 Request URL 发送 GET 请求,获得网页数据。




图 5.4 查看目标数据的 Headers

第二步：解析网页数据，获得 PORT、IP 和协议类型。

代码如下：

```
from lxml import etree
def get_content(url):
    headers = {'User-Agent': 'Mozilla/5.0 (Windows NT 6.1; Win64; x64) AppleWebKit/537.36 (KHTML, like Gecko) Chrome/80.0.3987.132 Safari/537.36'} # 加载伪装头防止反爬
    response = requests.get(url, headers=headers)
    if response.status_code == 200:
        print('连接正常')
        html = etree.HTML(response.text)
        IP = html.xpath('//td[@data-title="IP"]/text()')
        PORT = html.xpath('//td[@data-title="PORT"]/text()')
        TYPE = html.xpath('//td[@data-title="类型"]/text()')
        return IP, PORT, TYPE
    else:
        print('连接失败或遭遇反爬')
```

5.3.2 获取多页 IP

对获取的 IP、PORT 和协议类型封装成键值对的字典格式，并存储在字典列表中，以备监测可用性使用，代码实现如下：

```
import time
diclist = []
def get_url(page): # 传入的数据是爬取目标网页的页数
    for i in range(int(page)):
        try:
            print('正在爬取第 %d 页' % (i + 1))
            url = 'https://www.kuaidaili.com/free/inha/{}/'.format(i + 1)
            print("爬取网址为:", url)
            IP, PORT, TYPE = get_content(url) # 这是一个自定义解析网页内容的方法
            for i in range(len(IP)):
                dic = {}
                dic[TYPE[i]] = IP[i] + ':' + PORT[i]
                diclist.append(dic)
            time.sleep(3) # 防止访问频率过快，被封
        except Exception as e:
            print('爬取失败', e)
```

调用该方法之后程序执行结果如图 5.5 所示。

5.3.3 检测 IP 有效性

利用百度网页进行检测，将 IP 传入 proxies 参数中去验证，如果在规定的时间内返回的 state_code = 200，就说明 IP 是有效的，否则就报错，代码实现如下：

```
def check_ip(reg): # 网上检查 IP 的有效性
    url = 'https://www.baidu.com/'
    headers = {'User-Agent': 'Mozilla/5.0 (Windows NT 6.1; Win64; x64) AppleWebKit/537.36
```

```

正在爬取第1页
爬取网址为: https://www.kuaidaili.com/free/inha/1/
连接正常
正在爬取第2页
爬取网址为: https://www.kuaidaili.com/free/inha/2/
连接正常

[('HTTP': '113.96.62.246:8081'),
 ('HTTP': '183.195.106.118:8118'),
 ('HTTP': '121.13.252.61:41564'),
 ('HTTP': '222.78.6.70:8083'),
 ('HTTP': '14.215.212.37:9168'),
 ('HTTP': '111.59.199.58:8118'),
 ('HTTP': '117.114.149.66:55443'),
 ('HTTP': '27.42.168.46:55481'),
 ('HTTP': '106.15.197.250:8001'),
 ('HTTP': '47.243.68.117:8080'),
 ('HTTP': '152.136.62.181:9999'),
 ('HTTP': '152.136.62.181:9999'),
 ('HTTP': '218.75.102.198:8000'),
 ('HTTP': '183.247.215.218:30001'),
 ('HTTP': '47.243.190.108:28001')]

```

图 5.5 得到 IP 地址

```

(KHTML, like Gecko) Chrome/80.0.3987.132 Safari/537.36'}
can_use = []
for i in reg:
    try:
        response = requests.get(url, headers, proxies = i, timeout = 1)
        if response.status_code == 200:
            can_use.append(i)
    except Exception as e:
        print('出现问题', e)
return can_use

```

5.3.4 建立 IP 池

把检测有效的 IP 地址存储之后,就有了一个 IP 池,以备后续在爬取程序的时候,可以随机使用自己建立的 IP 池中的 IP 地址,代码如下:

```

can_ip = check_ip(diclist)
def save_ip(can_ip):
    with open('ip.txt', 'w+') as f:
        for i in data:
            f.write(str(i) + '\n')
    f.close()

```

5.4 付费 IP 代理使用

免费的 IP 往往效果不是很好,可以搭建 IP 代理池,但是搭建一个 IP 代理池成本很高,如果只是个人平时偶尔使用一下爬虫,也可以考虑付费 IP,几块钱买个几小时动态 IP,多数情况下都足够爬一个网站了。这里推荐一个付费代理“阿布云”代理。

“阿布云”代理网址: <https://www.abuyun.com/http-proxy/dyn-manual-python.html>,代码实现如下:

```
import requests
# 要访问的目标页面
targetUrl = "http://test.abuyun.com"
# targetUrl = "http://proxy.abuyun.com/switch-ip"
# targetUrl = "http://proxy.abuyun.com/current-ip"
# 代理服务器
proxyHost = "http-dyn.abuyun.com"
proxyPort = "9020"
# 代理隧道验证信息
proxyUser = "H01234567890123D"
proxyPass = "0123456789012345"
proxyMeta = "http:// %(user)s: %(pass)s@ %(host)s: %(port)s" % {
    "host": proxyHost,
    "port": proxyPort,
    "user": proxyUser,
    "pass": proxyPass,
}
proxies = {
    "http": proxyMeta,
    "https": proxyMeta,
}
resp = requests.get(targetUrl, proxies=proxies)
print (resp.status_code)
print( resp.text)
```

首次使用的话,可以选择购买一个小时的动态版试用,单击生成隧道代理信息作为凭证加入代码中即可。