ProxyPool

发布 *2.1.0*

2023 年 06 月 07 日

Contents

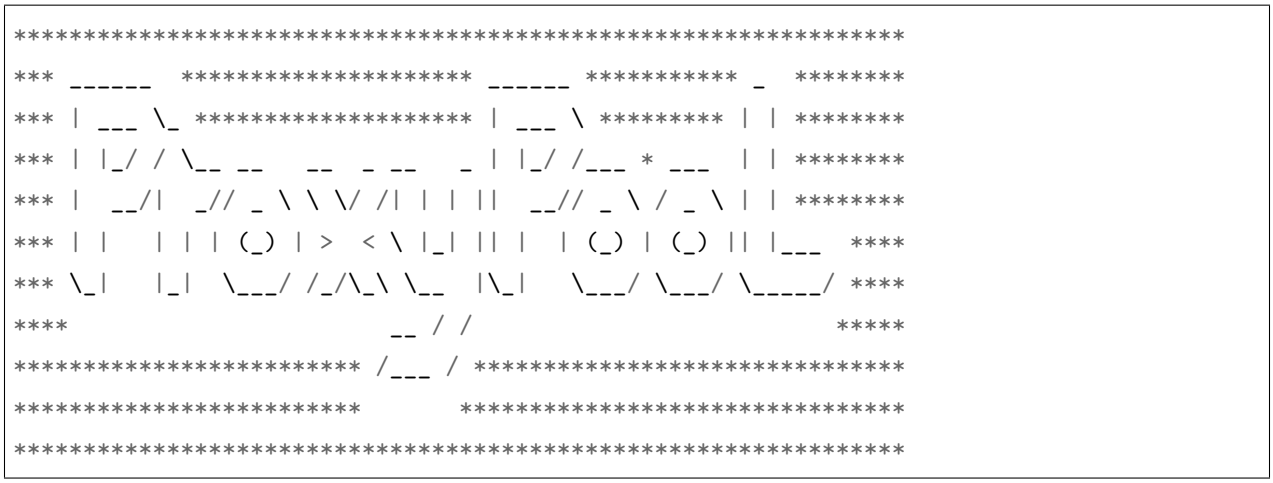

Python 爬虫代理 IP 池

CHAPTER 1

安装

- 下载代码

```
$ git clone git@github.com:jhao104/proxy_pool.git
```

- 安装依赖

```
$ pip install -r requirements.txt
```

- 更新配置

```
HOST = "0.0.0.0"
PORT = 5000

DB_CONN = 'redis://@127.0.0.1:8888'

PROXY_FETCHER = [
    "freeProxy01",
    "freeProxy02",
    # ....
]
```

- 启动项目

```
$ python proxyPool.py schedule
$ python proxyPool.py server
```

1.1 使用

- API
- 爬虫

```
import requests

def get_proxy():
    return requests.get("http://127.0.0.1:5010/get?type=https").json()

def delete_proxy(proxy):
    requests.get("http://127.0.0.1:5010/delete/?proxy={}".format(proxy))

# your spider code

def getHtml():
    # ....
    retry_count = 5
    proxy = get_proxy().get("proxy")
    while retry_count > 0:
        try:
            html = requests.get('https://www.example.com', proxies={"http": "http://{}".
↪format(proxy), "https": "https://{}".format(proxy)})
            # 使用代理访问
            return html
        except Exception:
            retry_count -= 1
            # 删除代理池中代理
            delete_proxy(proxy)
    return None
```

CHAPTER 2

Contents

2.1 用户指南

2.1.1 如何运行

下载代码

本项目需要下载代码到本地运行, 通过 `git` 下载:

```
$ git clone git@github.com:jhao104/proxy_pool.git
```

或者下载特定的 `release` 版本:

```
https://github.com/jhao104/proxy_pool/releases
```

安装依赖

到项目目录下使用 `pip` 安装依赖库:

```
$ pip install -r requirements.txt
```

更新配置

配置文件 setting.py 位于项目的主目录下:

```
# 配置 API 服务

HOST = "0.0.0.0"                # IP
PORT = 5000                     # 监听端口

# 配置数据库

DB_CONN = 'redis://@127.0.0.1:8888/0'

# 配置 ProxyFetcher

PROXY_FETCHER = [
    "freeProxy01",      # 这里是启用的代理抓取方法, 所有 fetch 方法位于 fetcher/
↪proxyFetcher.py
    "freeProxy02",
    # ....
]
```

更多配置请参考配置参考

启动项目

如果已配置好运行环境, 具备运行条件, 可以通过 proxyPool.py 启动. proxyPool.py 是项目的 CLI 入口. 完整程序包含两部份: schedule 调度程序和 server API 服务, 调度程序负责采集和验证代理, API 服务提供代理服务 HTTP 接口.

通过命令行程序分别启动调度程序和 API 服务:

```
# 启动调度程序
$ python proxyPool.py schedule

# 启动 webApi 服务
$ python proxyPool.py server
```

2.1.2 如何使用

爬虫代码要对接代理池目前有两种方式: 一是通过调用 API 接口使用, 二是直接读取数据库.

调用 API

启动 ProxyPool 的 server 后会提供如下几个 http 接口:

Api	Method	Description	Arg
/	GET	API 介绍	无
/get	GET	随机返回一个代理	无
/get_all	GET	返回所有代理	无
/get_status	GET	返回代理数量	无
/delete	GET	删除指定代理	proxy=host:ip

在代码中可以通过封装上面的 API 接口来使用代理, 例子:

```
import requests

def get_proxy():
    return requests.get("http://127.0.0.1:5010/get/").json()

def delete_proxy(proxy):
    requests.get("http://127.0.0.1:5010/delete/?proxy={}".format(proxy))

# your spider code

def getHtml():
    # ....
    retry_count = 5
    proxy = get_proxy().get("proxy")
    while retry_count > 0:
        try:
            # 使用代理访问
            html = requests.get('http://www.example.com', proxies={"http": "http://{}".
↪format(proxy)})
            return html
        except Exception:
            retry_count -= 1
            # 删除代理池中代理
            delete_proxy(proxy)
    return None
```

本例中我们在本地 127.0.0.1 启动端口为 5010 的 server, 使用 /get 接口获取代理, /delete 删除代理.

读数据库

目前支持配置两种数据库: REDIS 、SSDB.

- **REDIS** 储存结构为 hash, hash name 为配置项中的 **TABLE_NAME**
- **SSDB** 储存结构为 hash, hash name 为配置项中的 **TABLE_NAME**

可以在代码中自行读取.

2.1.3 配置参考

配置文件 setting.py 位于项目的主目录下, 配置主要分为四类: **服务配置**、**数据库配置**、**采集配置**、**校验配置**.

服务配置

- HOST

  API 服务监听的 IP, 本机访问设置为 127.0.0.1, 开启远程访问设置为: 0.0.0.0.

- PORT

  API 服务监听的端口.

数据库配置

- DB_CONN

  用户存放代理 IP 的数据库 URI, 配置格式为: db_type://[[user]:[pwd]]@ip:port/[db].

  目前支持的 db_type 有: ssdb 、redis.

  配置示例:

```
# SSDB IP: 127.0.0.1  Port: 8888
DB_CONN = 'ssdb://@127.0.0.1:8888'
# SSDB IP: 127.0.0.1  Port: 8899  Password:  123456
DB_CONN = 'ssdb://:123456@127.0.0.1:8888'

# Redis IP: 127.0.0.1  Port: 6379
DB_CONN = 'redis://@127.0.0.1:6379'
# Redis IP: 127.0.0.1  Port: 6379  Password:  123456
DB_CONN = 'redis://:123456@127.0.0.1:6379'
# Redis IP: 127.0.0.1  Port: 6379  Password:  123456  DB: 15
DB_CONN = 'redis://:123456@127.0.0.1:6379/15'
```

- TABLE_NAME

  存放代理的数据载体名称, ssdb 和 redis 的存放结构为 hash.

采集配置

- PROXY_FETCHER

  启用的代理采集方法名, 代理采集方法位于 fetcher/proxyFetcher.py 类中.

  由于各个代理源的稳定性不容易掌握, 当某个代理采集方法失效时, 可以该配置中注释掉其名称.

  如果有增加某些代理采集方法, 也请在该配置中添加其方法名, 具体请参考 /dev/extend_fetcher.

  调度程序每次执行采集任务时都会再次加载该配置, 保证每次运行的采集方法都是有效的.

校验配置

- HTTP_URL

  用于检验代理是否可用的地址, 默认为 http://httpbin.org, 可根据使用场景修改为其他地址.

- HTTPS_URL

  用于检验代理是否支持 HTTPS 的地址, 默认为 https://www.qq.com, 可根据使用场景修改为其他地址.

- VERIFY_TIMEOUT

  检验代理的超时时间, 默认为 10 , 单位秒. 使用代理访问 HTTP(S)_URL 耗时超过 VERIFY_TIMEOUT 时, 视为代理不可用.

- MAX_FAIL_COUNT

  检验代理允许最大失败次数, 默认为 0, 即出错一次即删除.

- POOL_SIZE_MIN

  代理检测定时任务运行前若代理数量小于 *POOL_SIZE_MIN*, 则先运行抓取程序.

2.2 开发指南

2.2.1 扩展代理源

项目默认包含几个免费的代理获取源, 但是免费的毕竟质量有限, 如果直接运行可能拿到的代理质量不理想。因此提供了用户自定义扩展代理获取的方法。

如果要添加一个新的代理获取方法, 过程如下:

1. 首先在 ProxyFetcher 类中添加自定义的获取代理的静态方法，该方法需要以生成器 (yield) 形式返回 host:ip 格式的代理字符串，例如:

```
class ProxyFetcher(object):
# ....
# 自定义代理源获取方法
@staticmethod
def freeProxyCustom01():  # 命名不和已有重复即可
    # 通过某网站或者某接口或某数据库获取代理
    # 假设你已经拿到了一个代理列表
    proxies = ["x.x.x.x:3128", "x.x.x.x:80"]
    for proxy in proxies:
        yield proxy
    # 确保每个 proxy 都是 host:ip 正确的格式返回
```

2. 添加好方法后，修改配置文件 setting.py 中的 PROXY_FETCHER 项，加入刚才添加的自定义方法的名字:

```
PROXY_FETCHER = [
    # ....
    "freeProxyCustom01"  #  # 确保名字和你添加方法名字一致
]
```

2.2.2 代理校验

内置校验

项目中使用的代理校验方法全部定义在 validator.py 中，通过 ProxyValidator 类中提供的装饰器来区分。校验方法返回 True 表示校验通过，返回 False 表示校验不通过。

- 代理校验方法分为三类: preValidator 、httpValidator 、httpsValidator:
  - **preValidator**: 预校验，在代理抓取后验证前调用，目前实现了 formatValidator 校验代理 IP 格式是否合法;
  - **httpValidator**: 代理可用性校验，通过则认为代理可用，目前实现了 httpTimeOutValidator 校验;
  - **httpsValidator**: 校验代理是否支持 https，目前实现了 httpsTimeOutValidator 校验。

每种校验可以定义多个方法，只有 **所有**方法都返回 True 的情况下才视为该校验通过，校验方法执行顺序为: 先执行 **httpValidator** ，前者通过后再执行 **httpsValidator** 。只有 *preValidator* 校验通过的代理才会进入可用性校验，*httpValidator* 校验通过后认为代理可用准备更新入代理池, *httpValidator* 校验通过后视为代理支持 https 更新代理的 *https* 属性为 *True* 。

扩展校验

在 validator.py 已有自定义校验的示例，自定义函数需返回 True 或者 False，使用 ProxyValidator 中提供的装饰器来区分校验类型。下面是两个例子:

- 1. 自定义一个代理可用性的校验 (addHttpValidator):

```
@ProxyValidator.addHttpValidator
def customValidatorExample01(proxy):
    """ 自定义代理可用性校验函数"""
    proxies = {"http": "http://{proxy}".format(proxy=proxy)}
    try:
        r = requests.get("http://www.baidu.com/", headers=HEADER, proxies=proxies,␣
↪timeout=5)
        return True if r.status_code == 200 and len(r.content) > 200 else False
    except Exception as e:
        return False
```

- 2. 自定义一个代理是否支持 https 的校验 (addHttpsValidator):

```
@ProxyValidator.addHttpsValidator
def customValidatorExample02(proxy):
    """ 自定义代理是否支持 https 校验函数"""
    proxies = {"https": "https://{proxy}".format(proxy=proxy)}
    try:
        r = requests.get("https://www.baidu.com/", headers=HEADER, proxies=proxies,␣
↪timeout=5, verify=False)
        return True if r.status_code == 200 and len(r.content) > 200 else False
    except Exception as e:
        return False
```

注意，比如在运行代理可用性校验时，所有被 ProxyValidator.addHttpValidator 装饰的函数会被依次按定义顺序执行，只有当所有函数都返回 True 时才会判断代理可用。HttpsValidator 运行机制也是如此。

2.3 ChangeLog

2.3.1 develop

1. 代理格式检查支持需认证的代理格式 *username:password@ip:port* ; (2023-03-10)
2. 新增代理源 **稻壳代理**; (2023-05-15)

2.3.2 2.4.1 (2022-07-17)

1. 新增代理源 **FreeProxyList**; (2022-07-21)
2. 新增代理源 **FateZero**; (2022-08-01)
3. 新增代理属性 `region`; (2022-08-16)

2.3.3 2.4.0 (2021-11-17)

1. 移除无效代理源 **神鸡代理**; (2021-11-16)
2. 移除无效代理源 **极速代理**; (2021-11-16)
3. 移除代理源 **西拉代理**; (2021-11-16)
4. 新增代理源 **蝶鸟 IP**; (2021-11-16)
5. 新增代理源 **PROXY11**; (2021-11-16)
6. 多线程采集代理; (2021-11-17)

2.3.4 2.3.0 (2021-05-27)

1. 修复 Dockerfile 时区问题; (2021-04-12)
2. 新增 Proxy 属性 `source`, 标记代理来源; (2021-04-13)
3. 新增 Proxy 属性 `https`, 标记支持 https 的代理; (2021-05-27)

2.3.5 2.2.0 (2021-04-08)

1. 启动时检查数据库连通性;
2. 新增免费代理源 **米扑代理**;
3. 新增免费代理源 **Pzzqz**;
4. 新增免费代理源 **神鸡代理**;
5. 新增免费代理源 **极速代理**;
6. 新增免费代理源 **小幻代理**;

2.3.6 2.1.1 (2021-02-23)

1. Fix Bug #493, 新增时区配置; (2020-08-12)
2. 修复 **66 代理**采集; (2020-11-04)
3. 修复 **全网代理**采集, 解决 HTML 端口加密问题; (2020-11-04)

4. 新增 **代理盒子**免费源; (2020-11-04)
5. 新增 `POOL_SIZE_MIN` 配置项, runProxyCheck 时, 剩余代理少于 POOL_SIZE_MIN 触发抓取; (2021-02-23)

2.3.7 2.1.0 (2020.07)

1. 新增免费代理源 **西拉代理**（2020-03-30）
2. Fix Bug #356 #401
3. 优化 Docker 镜像体积; (2020-06-19)
4. 优化配置方式;
5. 优化代码结构;
6. 不再储存 raw_proxy, 抓取后直接验证入库;

2.3.8 2.0.1 (2019.10)

1. 新增免费代理源 **89 免费代理**;
2. 新增免费代理源 **齐云代理**

2.3.9 2.0.0 (2019.08)

1. WebApi 集成 Gunicorn 方式启动, Windows 平台暂不支持;
2. 优化 Proxy 调度程序;
3. 扩展 Proxy 属性;
4. 新增 cli 工具, 更加方便启动 proxyPool

2.3.10 1.14 (2019.07)

1. 修复 Queue 阻塞导致的 `ProxyValidSchedule` 假死 bug;
2. 修改代理源 **云代理**抓取;
3. 修改代理源 **码农代理**抓取;
4. 修改代理源 **代理 66** 抓取, 引入 `PyExecJS` 模块破解加速乐动态 Cookies 加密;

2.3.11 1.13 (2019.02)

1. 使用.py 文件替换.ini 作为配置文件;
2. 优化代理采集部分;

2.3.12 1.12 (2018.04)

1. 优化代理格式检查;
2. 增加代理源;
3. fix bug #122 #126

2.3.13 1.11 (2017.08)

1. 使用多线程验证 useful_pool;

2.3.14 1.10 (2016.11)

1. 第一版;
2. 支持 PY2/PY3;
3. 代理池基本功能;

Python 模块索引

d

u

索引