PYTHON编写知乎爬虫实践

分享大纲

- 爬虫工作原理
- 网页抓取、去重、解析和存储相关技术栈
- Bloom Filter算法介绍
- 使用redis queue实现大规模网页抓取
- 反爬虫策略及应对措施
- QA

从种子URL获取HTML源代码说起

```python
# 基本demo，获取html源代码

import requests

def send_request(url):
    # 通过requests库来发送一个http请求，并且获取
    # 网页内容
    try:
        r = requests.get(url)
    except Exception as e:
        print e
        return
    html_source = r.text

    return html_source

# 调用
html_source = send_request("http://www.qq.com/")

print html_source
```

DEMO解释

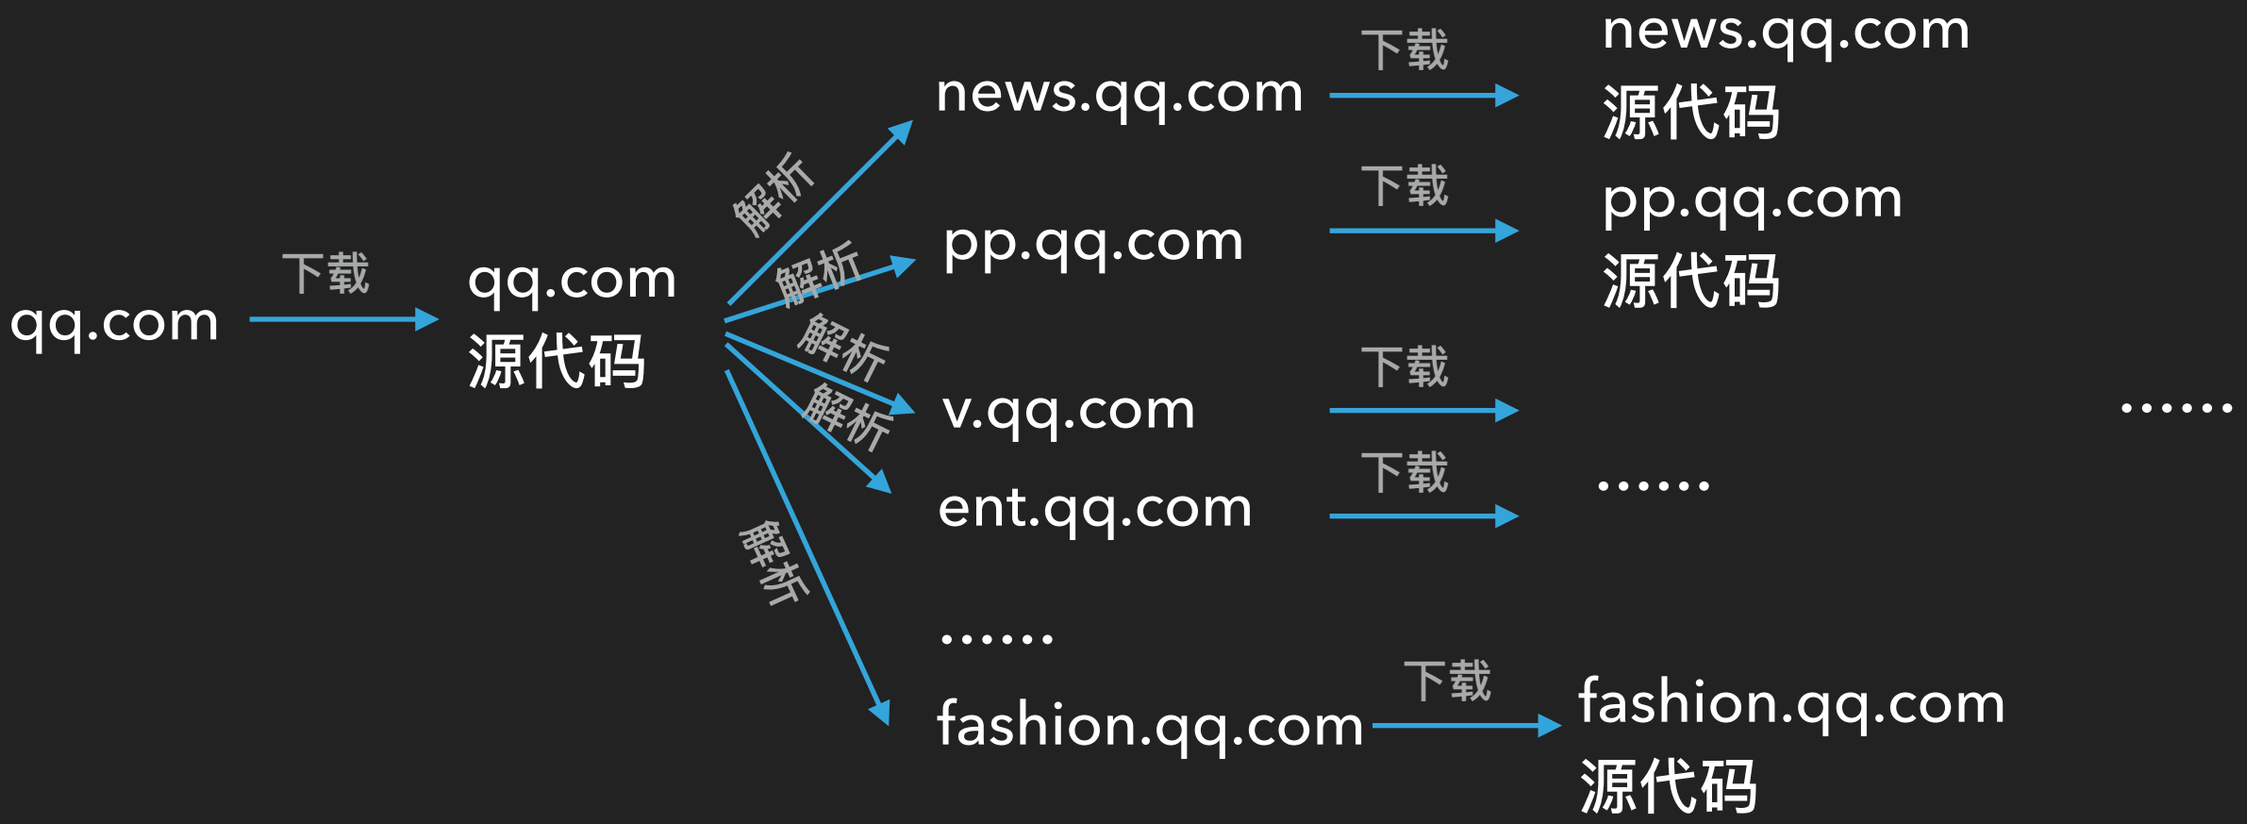

引入URL队列模型

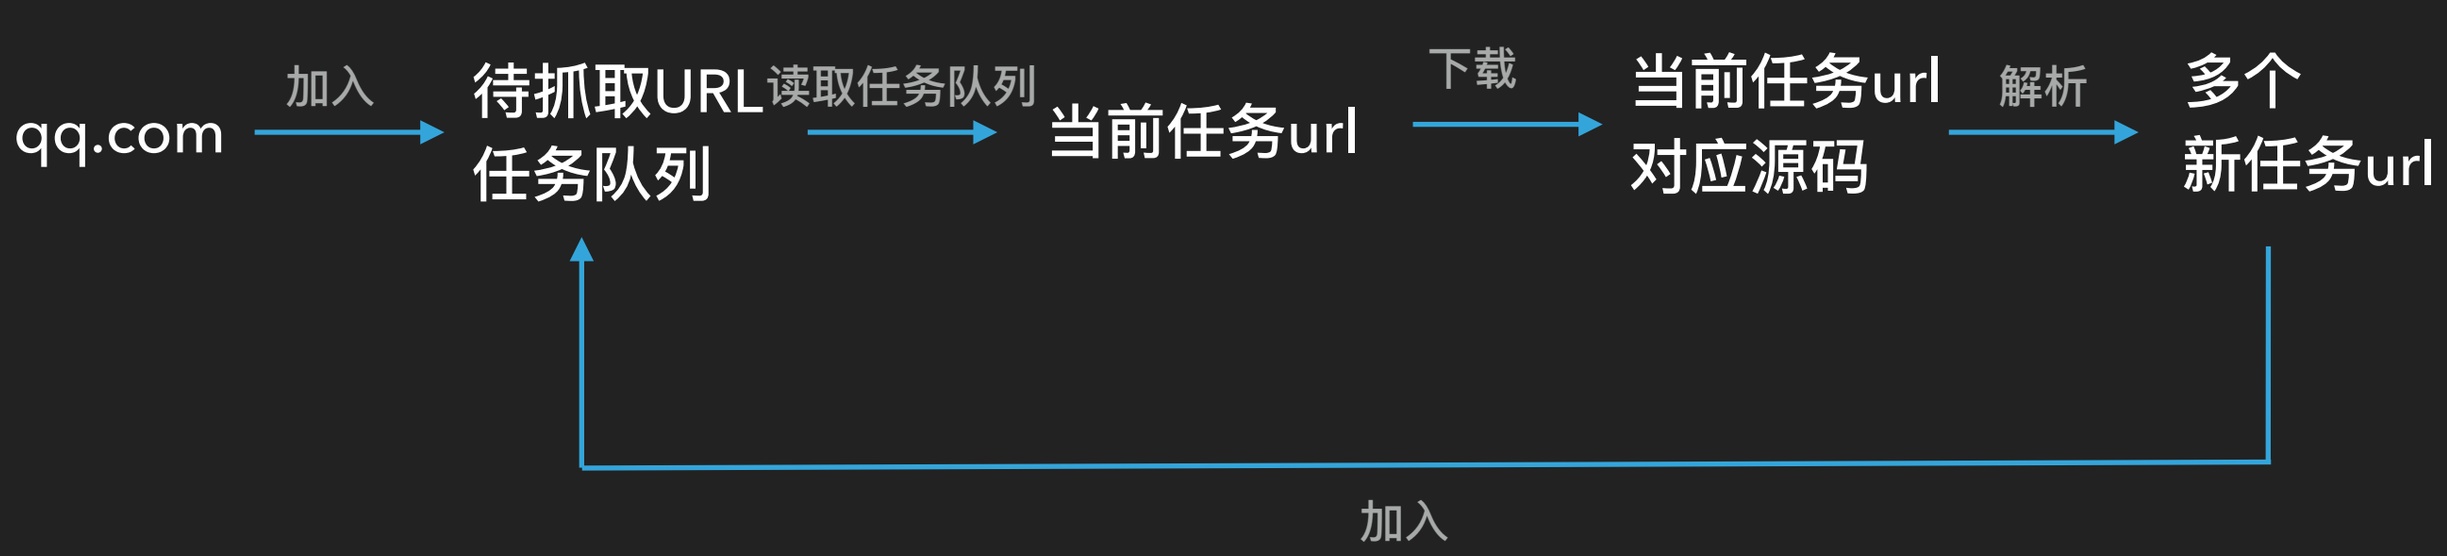

通俗易懂的伪代码

```
import Queue

seed_url = "http://www.qq.com/"    # 种子url
url_queue = Queue.Queue()          # url任务队列
seen = set()                       # 存储已经执行过的url任务
seen.insert(seed_url)              # 加入初始的种子url
url_queue.put(seed_url)            # 标记初始的种子url为已经执行

while(True) : #一直进行
    if url_queue.size() > 0 :
        curr_url = url_queue.get()                  #拿出队例中第一个的url
        store(curr_url)                             #把这个url代表的网页存储好
        for next_url in extract_urls(curr_url):     #提取把这个url里链向的url
            if next_url not in seen:
                seen.put(next_url)
                url_queue.put(next_url)             #将提取出的url加入到任务队列
    else:
        break
```

爬虫的基本流程总结

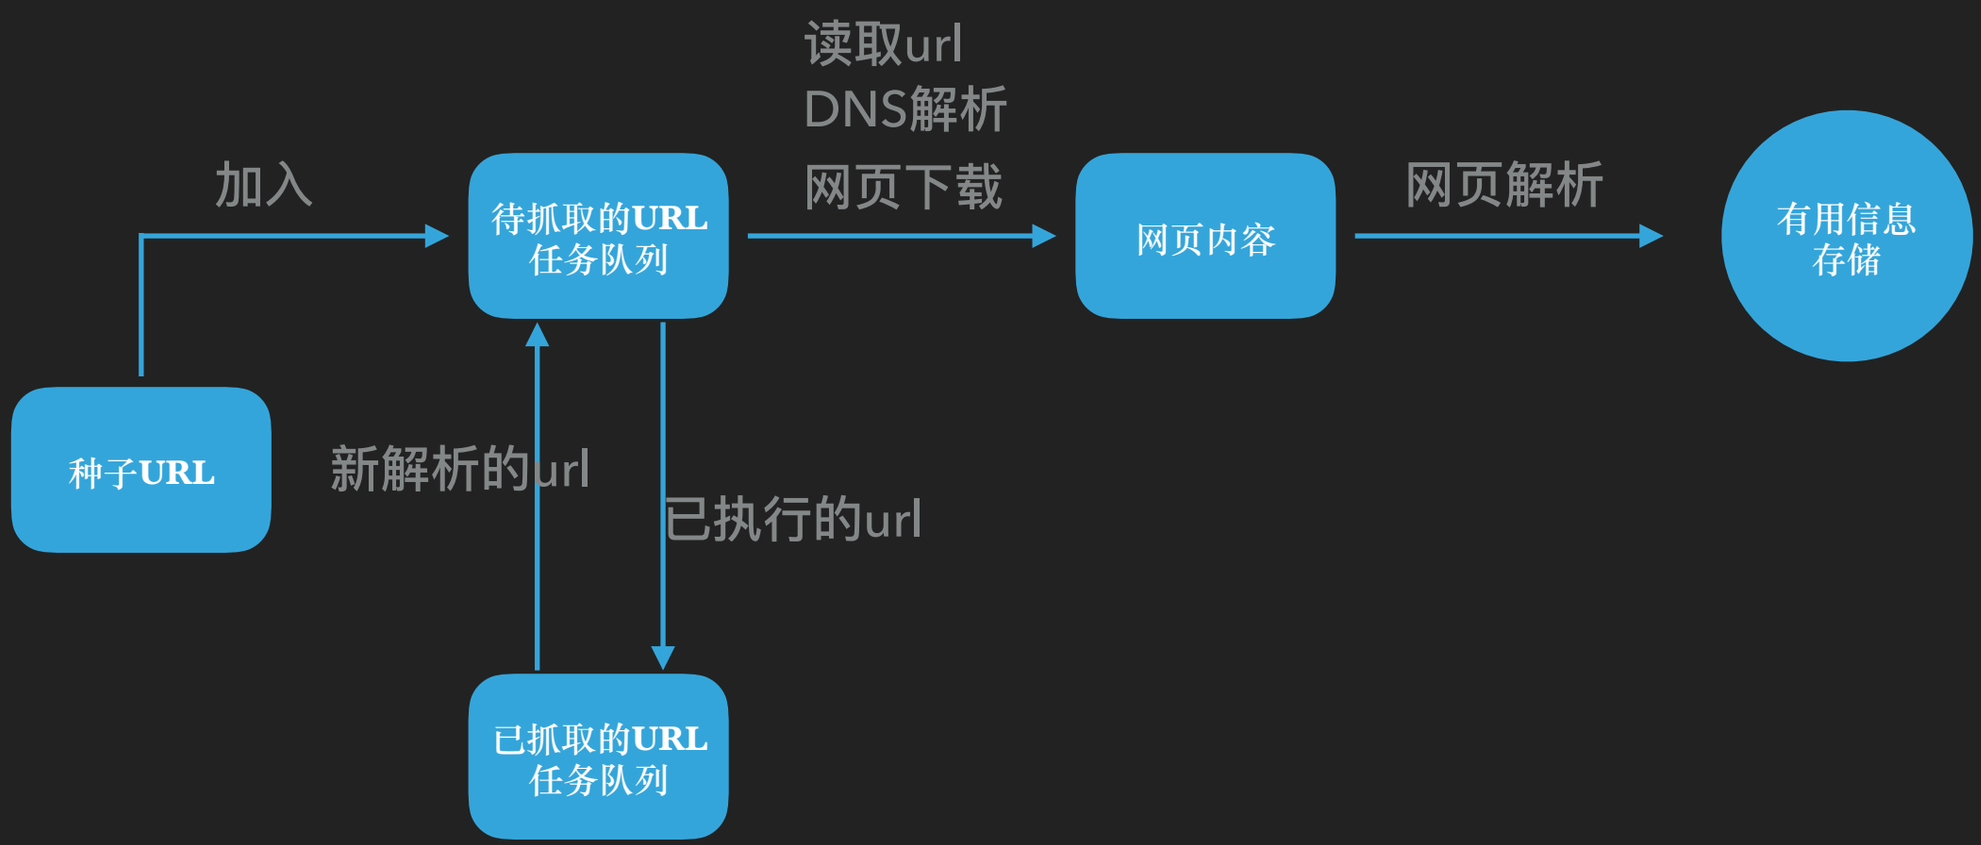

爬虫的抓取策略

- 深度优先策略
- 广度优先策略

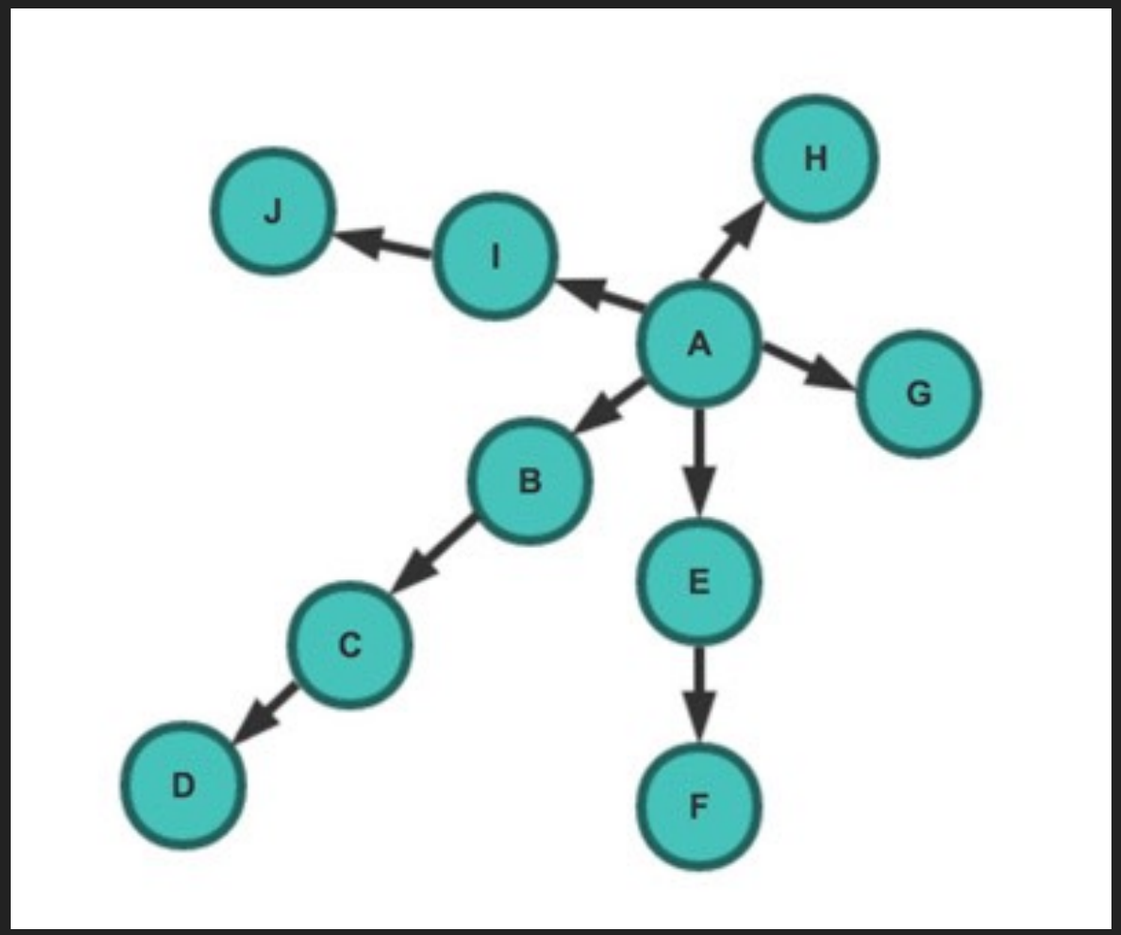

复杂点的例子：图片抓取程序

```python
#!/usr/bin/python
# -*- coding: utf-8 -*-
import urllib2
import re
from os.path import basename
from urlparse import urlsplit

def get_page(url):
    url = url + "?see_lz=1"
    url_content = urllib2.urlopen(url).read()
    page = '<span class="red">(.*?)</span>'
    the_page = re.findall(page, url_content)
    return int(the_page[0])

def download_img(url):
    url_content = urllib2.urlopen(url).read()
    spans = '<cc>(.*?)</cc>'
    ss = re.findall(spans, url_content)
    ob_imgs = ','.join(ss)
    img_urls = re.findall('img .*?src="(.*?)"', ob_imgs)
    for img_url in img_urls:
        try:
            img_data = urllib2.urlopen(img_url).read()
            file_name = 'images/' + basename(urlsplit(img_url)[2])
            output = open(file_name,'wb')
            output.write(img_data)
            output.close()
        except Exception as e:
            print e

def start(url):
    numb = get_page(url)
    cont = 0
    print "总共有" + str(numb) + " 页."
    while cont < numb:
        cont += 1
        print "Downloading " + url + "?see_lz=1&pn=" + str(cont) + "..."
        download_img(url + "?see_lz=1&pn=" + str(cont))
    print 'Completed!'

start("http://tieba.baidu.com/p/2166231880")
```

技术栈

- 网页抓取：urllib2、urllib3、requests
- 去重：set、Bloom Filter
- 解析：re、XPath、BeautifulSoup
- 存储：MySQL、Mongodb、Redis
- 并发抓取：rq、scrapy、celery、thread、multiprocess

几个比较常见的例子

- 字处理软件中，需要检查一个英语单词是否拼写正确
- 在 FBI，一个嫌疑人的名字是否已经在嫌疑名单上
- 在网络爬虫里，一个网址是否被访问过
- yahoo, gmail等邮箱垃圾邮件过滤功能

如何判断一个元素是否存在一个集合中?

- 数组
- 链表
- 树、平衡二叉树
- Trie
- 哈希表

哈希函数

- 将任意大小的数据转换成特定大小的数据的函数
- 转换后的数据称为哈希值或哈希编码

- 特点：
  - 如果两个散列值是不相同的（根据同一函数），那么这两个散列值的原始输入也是不相同的
  - 不同的输入可能对应相同的输出（哈希碰撞）

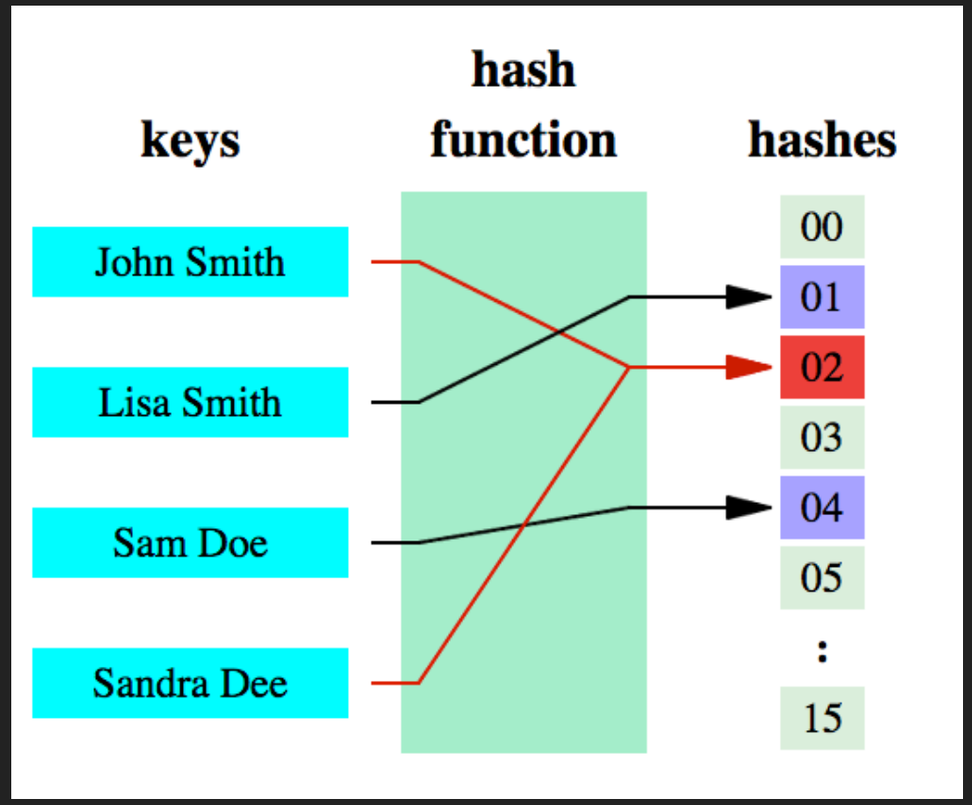

哈希表

- 根据关键码值(Key value)而直接进行访问的数据结构
- 拉链法解决哈希冲突

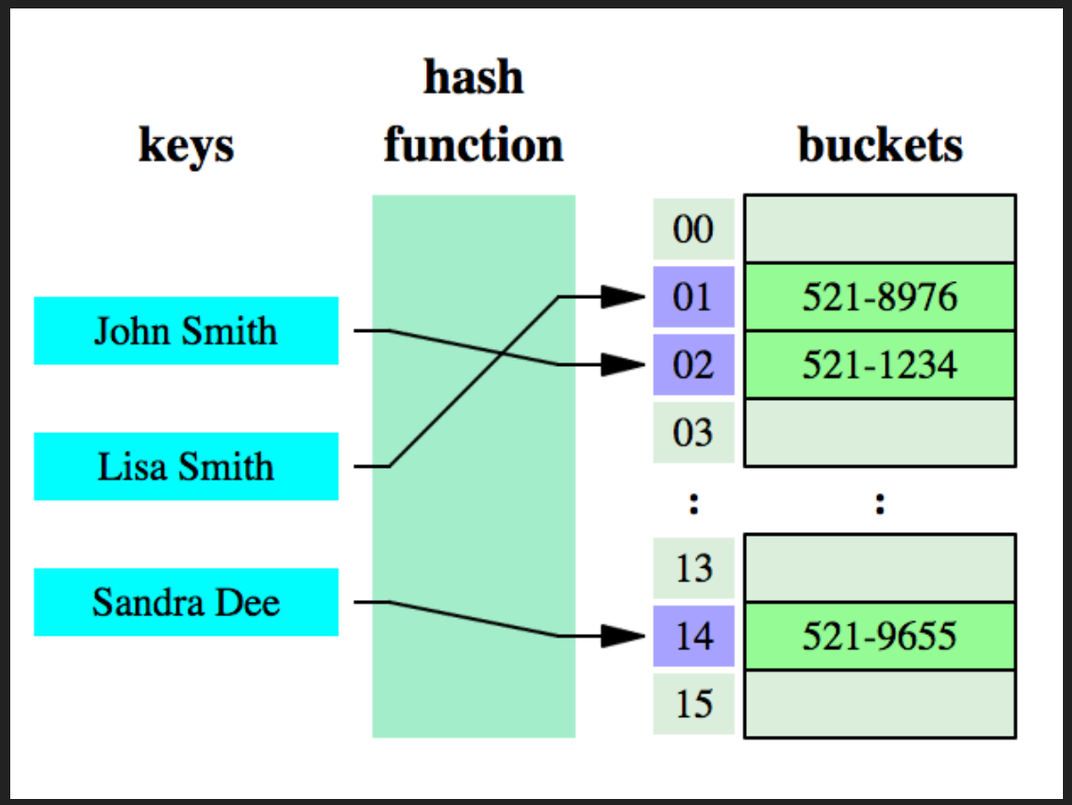

使用哈希表存储一亿 个垃圾 EMAIL 地址的消耗?

- 哈希函数将一个email地址映射成8字节信息指纹
- 哈希表存储效率通常小于50%（哈希冲突）
- 消耗的内存：8 * 2 * 1亿 字节 = 1.6G 内存

布隆过滤器（BLOOM FILTER）

- 巴顿.布隆于一九七零年提出
- 一个很长的二进制向量（位数组）
- 一系列随机函数(哈希)
- 空间效率和查询效率高
- 有一定的误判率（哈希表是精确匹配）

布隆过滤器的实现要求

- 长度为m的位数组
- k个独立的良好的哈希函数
  - 均匀的随机分布
  - 哈希冲突低
- k远小于m
- m和容纳的元素之间存在比例
- m 和 k的值取决于误判率

直观的描述

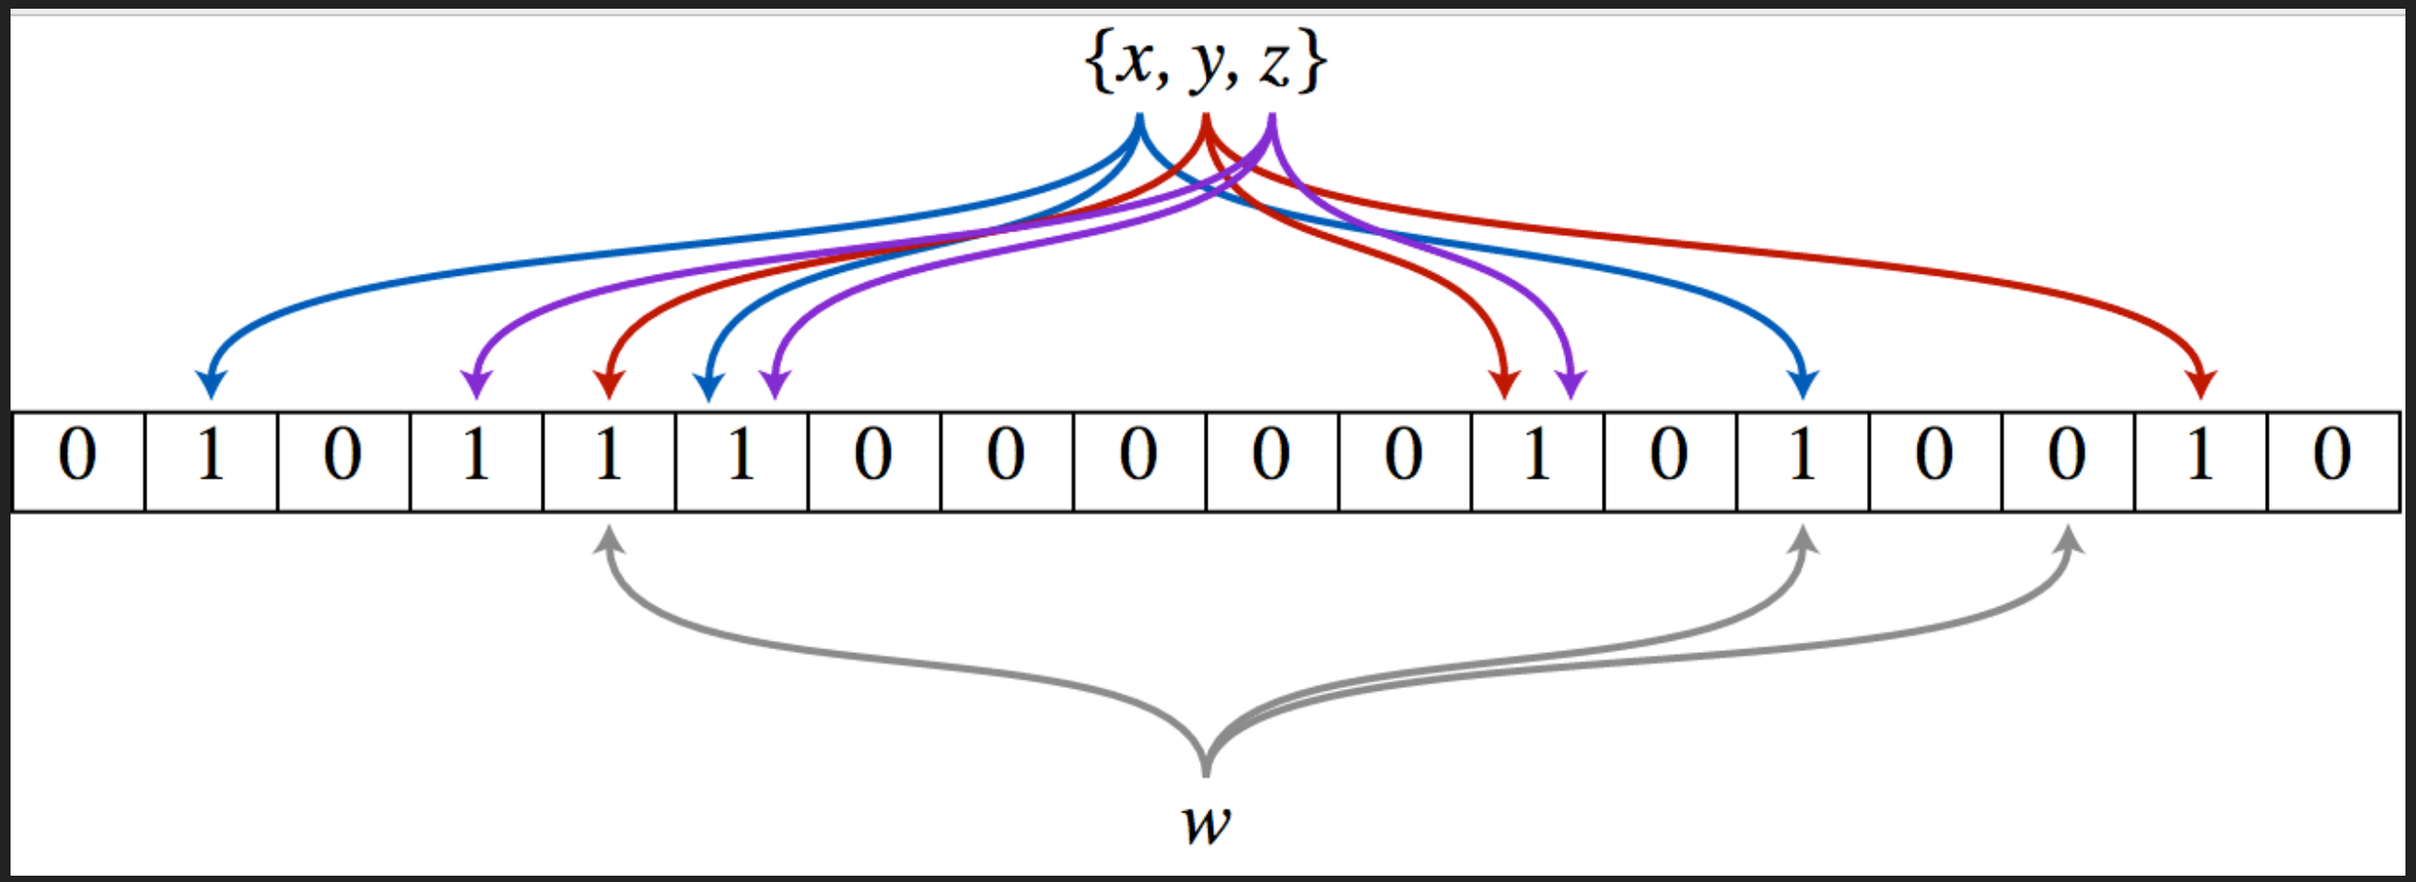

布隆过滤器添加元素

- 将要添加的元素给k个哈希函数
- 得到对应于位数组上的k个位置
- 将这k个位置设为1

布隆过滤器查询元素

- 将要查询的元素给k个哈希函数
- 得到对应于位数组上的k个位置
- 如果k个位置有一个为0，则肯定不在集合中
- 如果k个位置全部为1，则可能在集合中 误判率存在的原因

布隆过滤器高效的原因

- 普通数据结构都存取元素
- Bloom filter只需存取要一个位数组
- 查询效率O(k)

布隆过滤器的简单实现

```
import csv
import mmh3
from bitarray import bitarray



size =   5000000;
bit_array = bitarray(size)
bit_array.setall(0)

def mapf(url):
        b1 = mmh3.hash(url, 41) % size
        bit_array[b1]=1

        b2 = mmh3.hash(url, 42) % size
        bit_array[b2]=1

        b3 = mmh3.hash(url, 43) % size
        bit_array[b3]=1

        b4 = mmh3.hash(url, 44) % size
        bit_array[b4]=1

        b5 = mmh3.hash(url, 45) % size
        bit_array[b5]=1

        b6 = mmh3.hash(url, 46) % size
        bit_array[b6]=1

        b7 = mmh3.hash(url, 47) % size
        bit_array[b7]=1


#r = csv.reader(open("C:\\Users\\tarun_000\\Desktop\\top1m.csv"));
r = csv.reader(open("top1m.csv"));
for row in r:
        url=row[1]
        mapf(url);
#print line[1]
```

```
def check(url):
        global disk_accesses
        b1 = mmh3.hash(url, 41) % size
        b2 = mmh3.hash(url, 42) % size
        b3 = mmh3.hash(url, 43) % size
        b4 = mmh3.hash(url, 44) % size
        b5 = mmh3.hash(url, 45) % size
        b6 = mmh3.hash(url, 46) % size
        b7 = mmh3.hash(url, 47) % size
        if ba[b1]==True and
ba[b2]==True and
ba[b3]==True and
ba[b4]==True and
ba[b5]==True and
ba[b6]==True and
ba[b7]==True:
        print "maybe malicious...making disc access now to be safe...
        disk_accesses=disk_accesses+1;
else:
    print "definitely not malicious...can proceed without disc lookup
```

消息队列-生产者消费者模式介绍

- 元素：生产者、消费者、任务队列
- 调度：round-robin、权重调度
- 消息ack确认

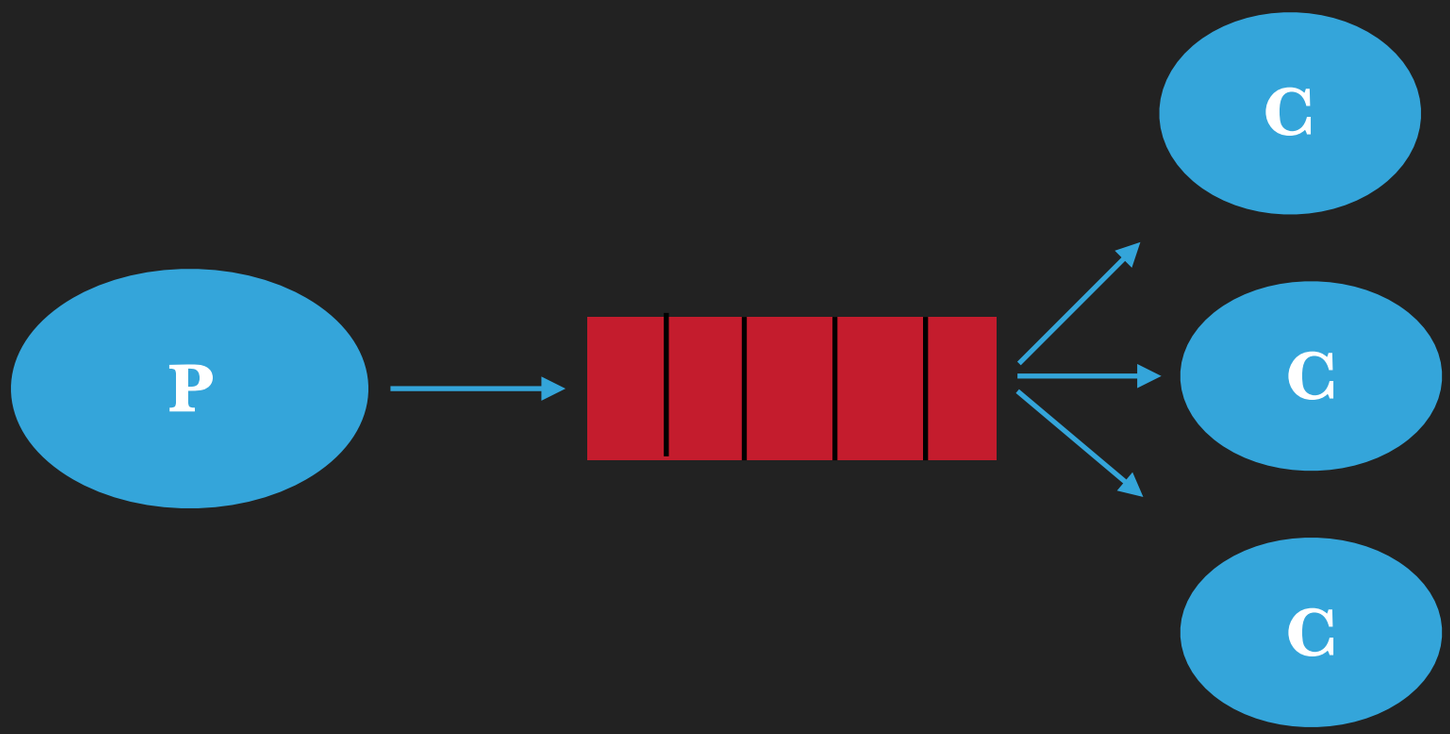

rq示例

worker.py 后台执行进程

```python
# worker.py
import os

import redis
from rq import Worker, Queue, Connection

listen = ['high', 'default', 'low']

redis_url = os.getenv('REDISTOGO_URL', 'redis://localhost:6379')

conn = redis.from_url(redis_url)

if __name__ == '__main__':
    with Connection(conn):
        worker = Worker(map(Queue, listen))
        worker.work()
```

my_module.py 工具函数

```python
# my_module.py

import requests

def count_words_at_url(url):
    resp = requests.get(url)
    return len(resp.text.split())
```

main.py 主入口

```python
# main.py

from my_module import count_words_at_url
from rq import Queue, use_connection

use_connection()
q = Queue()

if __name__ == '__main__':
    result = q.enqueue(count_words_at_url, 'http://qq.com')

```

第四部分：使用REDIS QUEUE实现大规模网页抓取

截图

```
om') (29df42cd-3c0d-4cba-80fc-91b7e3f2eb0c)
16:11:48 default: Job OK (29df42cd-3c0d-4cba-80fc-91b7e3f2e
b0c)
16:11:48 Result is kept for 500 seconds
16:11:48
16:11:48 *** Listening on high, default, low...
16:11:57 default: my_module.count_words_at_url('http://qq.c
om') (78a847ee-5fd5-4d4d-b7e0-fb57b6944366)
16:11:58 default: Job OK (78a847ee-5fd5-4d4d-b7e0-fb57b6944
366)
16:11:58 Result is kept for 500 seconds
16:11:58
16:11:58 *** Listening on high, default, low...
16:12:37 default: my_module.count_words_at_url('http://qq.c
om') (1838407a-5011-4654-8406-e8825296cd79)
16:12:38 default: Job OK (1838407a-5011-4654-8406-e8825296c
d79)
16:12:38 Result is kept for 500 seconds
16:12:38
16:12:38 *** Listening on high, default, low...
```

```
→ 07-rq python main.py
→ 07-rq python main.py
→ 07-rq python main.py
→ 07-rq python main.py
→ 07-rq
```

python (Python)

```
om') (9a795067-7dae-48dd-8243-7188a1c9568c)
16:11:49 default: Job OK (9a795067-7dae-48dd-8243-7188a1c95
68c)
16:11:49 Result is kept for 500 seconds
16:11:49
16:11:49 *** Listening on high, default, low...
16:12:00 default: my_module.count_words_at_url('http://qq.c
om') (3293b023-6dda-41e8-8bb5-261459c77970)
16:12:00 default: Job OK (3293b023-6dda-41e8-8bb5-261459c77
970)
16:12:00 Result is kept for 500 seconds
16:12:00
16:12:00 *** Listening on high, default, low...
16:12:37 default: my_module.count_words_at_url('http://qq.c
om') (165b09e5-9f5d-4c28-8158-11feb7df7db6)
16:12:38 default: Job OK (165b09e5-9f5d-4c28-8158-11feb7df7
db6)
16:12:38 Result is kept for 500 seconds
16:12:38
16:12:38 *** Listening on high, default, low...
```

常见站点爬虫攻防

- 用户代理检测： 通过设置User-Agent header
- Referer检测： 通过设置Referer header
- 登陆限制：通过模拟登陆解决
- 访问频率限制：
  - 同一账号的频率限制，则可以使用多个账号轮流发请求
  - 如果针对IP，可通过IP代理池

各种浏览器的user-agent

- IE 8: Mozilla/4.0 (compatible; MSIE 8.0; Windows NT 6.0)
- IE 7: Mozilla/4.0 (compatible; MSIE 7.0; Windows NT 5.2)
- IE 6: Mozilla/4.0 (compatible; MSIE 6.0; Windows NT 5.1)
- chrome: Mozilla/5.0 (Macintosh; Intel Mac OS X 10_12_1) AppleWebKit/537.36 (KHTML, like Gecko) Chrome/59.0.3071.115 Safari/537.36
- safari: "Mozilla/5.0 (Macintosh; Intel Mac OS X 10_12_1) AppleWebKit/602.2.14 (KHTML, like Gecko) Version/10.0.1 Safari/602.2.14"

网站反“反盗链”

- referer：用于告知服务器用户的来源页面
- 某些站点会检测是否存在referer
- 资源站点反盗链

```
cookies = {
    "d_c0": "AECA7v-aPwqPTiIbemmIQ8abhJy7bdD2VgE=|1468847182",
    "login": "NzM5ZDc2M2JkYzYwNDZlOGJlYWQ1YmI4OTg5NDhmMTY=|1480901173|9c296f424b32f241d1471203244eaf30729420f0",
    "n_c": "1",
    "q_c1": "395b12e529e541cbb400e9718395e346|1479808003000|1468847182000",
    "l_cap_id": "NzI0MTQwZGY2NjQyNDQ1NThmYTY0MjJhYmU2NmExMGY=|1480901160|2e7a7faee3b3e8d0afb550e8e7b38d86c15a31bc",
    "d_c0": "AECA7v-aPwqPTiIbemmIQ8abhJy7bdD2VgE=|1468847182",
    "cap_id": "N2U1NmQwODQ1NjFiNGI2Yzg2YTE2NzJkOTU5N2E0NjI=|1480901160|fd59e2ed79faacc2be1010687d27dd559ec1552a"
}

headers = {
    "User-Agent": "Mozilla/5.0 (Macintosh; Intel Mac OS X 10_12_1) AppleWebKit/537.36 (KHTML, like Gecko) Chrome/54.0.284
    "Referer": "https://www.zhihu.com/"
}

r = requests.get(url, cookies = cookies, headers = headers)
```

代理IP池

```python
import requests
import random

class Proxy:

    def __init__(self):
        self.cache_ip_list = []

    # 从代理的IP池子里面获取某个ip
    def get_random_ip(self):
        if not len(self.cache_ip_list):
            api_url = 'http://api.xicidaili.com/free2016.txt'
            try:
                r = requests.get(api_url)
                ip_list = r.text.split('\r\n')
                self.cache_ip_list = ip_list
            except Exception as e:
                # 异常情况不返回任何ip，这个时候即不使用代理
                print e
                return {}

        proxy_ip = random.choice(self.cache_ip_list)
        proxies = {'http': 'http://' + proxy_ip}
        return proxies
```

Thanks for attending.