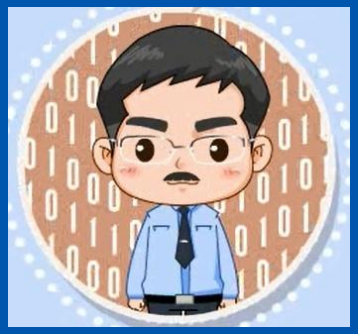

《数据采集与预处理》

教材官网： http://dblab.xmu.edu.cn/post/data-collection/

温馨提示：编辑幻灯片母版，可以修改每页PPT的厦大校徽和底部文字

第3章 网络数据采集

（PPT版本号：2022年1月版本）

林子雨 副教授

厦门大学计算机科学与技术系

E-mail: ziyulin@xmu.edu.cn

主页：**http://dblab.xmu.edu.cn/linziyu**

提纲

3.1 网络爬虫概述
3.2 网页基础知识
3.3 用Python实现HTTP请求
3.4 定制requests
3.5解析网页
3.6 综合实例
3.7 Scrapy爬虫

本PPT是以下教材的配套讲义
林子雨编著《数据采集与预处理》
人民邮电出版社

教材官网：
http://dblab.xmu.edu.cn/post/data-collection

3.1 网络爬虫概述

3.1.1 什么是网络爬虫
3.1.2 网络爬虫的类型
3.1.3 反爬机制

3.1.1 什么是网络爬虫

网络爬虫是一个自动提取网页的程序，它为搜索引擎从万维网上下载网页，是搜索引擎的重要组成部分。如图3-1所示，爬虫从一个或若干个初始网页的URL开始，获得初始网页上的URL，在抓取网页的过程中，不断从当前页面上抽取新的URL放入队列，直到满足系统的一定停止条件。

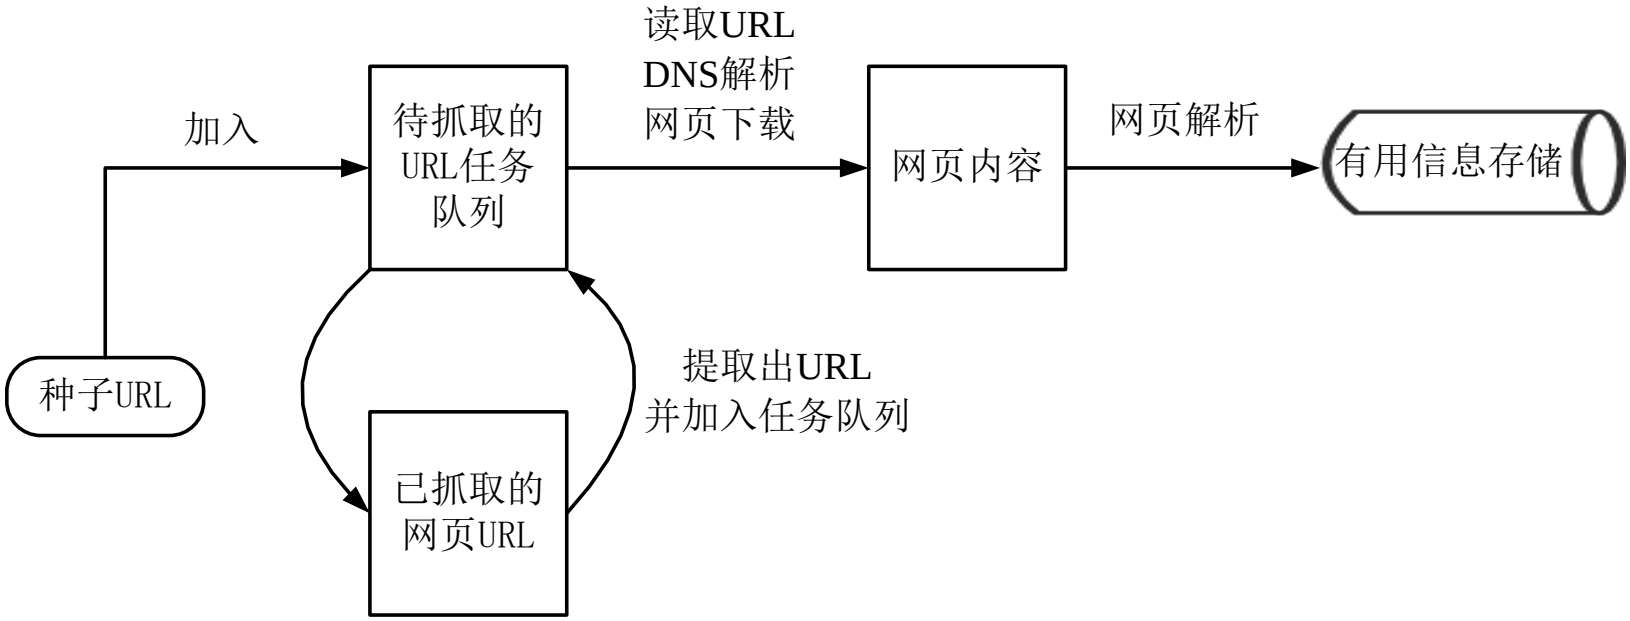

图3-1 网络爬虫的工作原理

3.1.2网络爬虫的类型

网络爬虫的类型可以分为：

- 通用网络爬虫
- 聚焦网络爬虫
- 增量式网络爬虫
- 深层网络爬虫

3.1.3反爬机制

为什么会有反爬机制？原因主要有两点：

- 第一，在大数据时代，数据是十分宝贵的财富，很多企业不愿意让自己的数据被别人免费获取，因此，很多企业都为自己的网站运用了反爬机制，防止网页上的数据被爬走；
- 第二，简单低级的网络爬虫，数据采集速度快，伪装度低，如果没有反爬机制，它们可以很快地抓取大量数据，甚至因为请求过多，造成网站服务器不能正常工作，影响了企业的业务开展。

反爬机制也是一把双刃剑，一方面可以保护企业网站和网站数据，但是，另一方面，如果反爬机制过于严格，可能会误伤到真正的用户请求，也就是真正用户的请求被错误当成网络爬虫而被拒绝访问。如果既要和“网络爬虫”死磕，又要保证很低的误伤率，那么又会增加网站研发的成本。

3.2 网页基础知识

3.2.1 超文本和HTML

3.2.2 HTTP

3.2.1 超文本和HTML

超文本（Hypertext）是指使用超链接的方法，把文字和图片信息相互联结，形成具有相关信息的体系。超文本的格式有很多，目前最常使用的是超文本标记语言HTML（Hyper Text Markup Language），我们平时在浏览器里面看到的网页就是由HTML解析而成的。下面是网页文件web_demo.html的HTML源代码：

```
<html><head><title>搜索指数</title></head>
<body>
<table>
<tr><td>排名</td><td>关键词</td><td>搜索指数</td></tr>
<tr><td>1</td><td>大数据</td><td>187767</td></tr>
<tr><td>2</td><td>云计算</td><td>178856</td></tr>
<tr><td>3</td><td>物联网</td><td>122376</td></tr>
</table>
</body>
</html>
```

3.2.1 超文本和HTML

使用网页浏览器（比如IE、Firefox等）打开这个网页文件，就会看到如图3-2所示的网页内容。

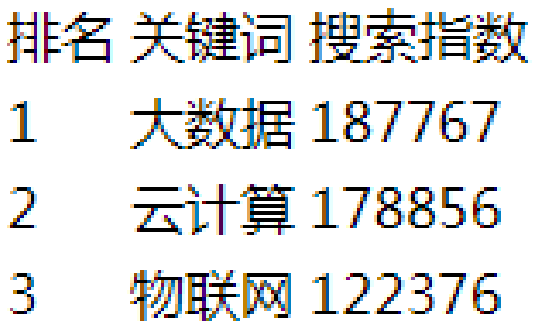

图3-2 网页文件显示效果

3.2.2 HTTP

HTTP是由万维网协会（World Wide Web Consortium）和 Internet 工作小组IETF（Internet Engineering Task Force）共同制定的规范。HTTP的全称是“Hyper Text Transfer Protocol”，中文名叫做“超文本传输协议”。HTTP协议是用于从网络传输超文本数据到本地浏览器的传送协议，它能保证高效而准确地传送超文本内容。

HTTP是基于“客户端/服务器”架构进行通信的，HTTP的服务器端实现程序有httpd、nginx等，客户端的实现程序主要是Web浏览器，例如Firefox、Internet Explorer、Google Chrome、Safari、Opera等。Web浏览器和Web服务器之间可以通过HTTP进行通信。

3.2.2 HTTP

一个典型的HTTP请求过程如下（如图3-3所示）：

（1）用户在浏览器中输入网址，比如http://dblab.xmu.edu.cn，浏览器向网页服务器发起请求；

（2）网页服务器接收用户访问请求，处理请求，产生响应（即把处理结果以HTML形式返回给浏览器）；

（3）浏览器接收来自网页服务器的HTML内容，进行渲染以后展示给用户。

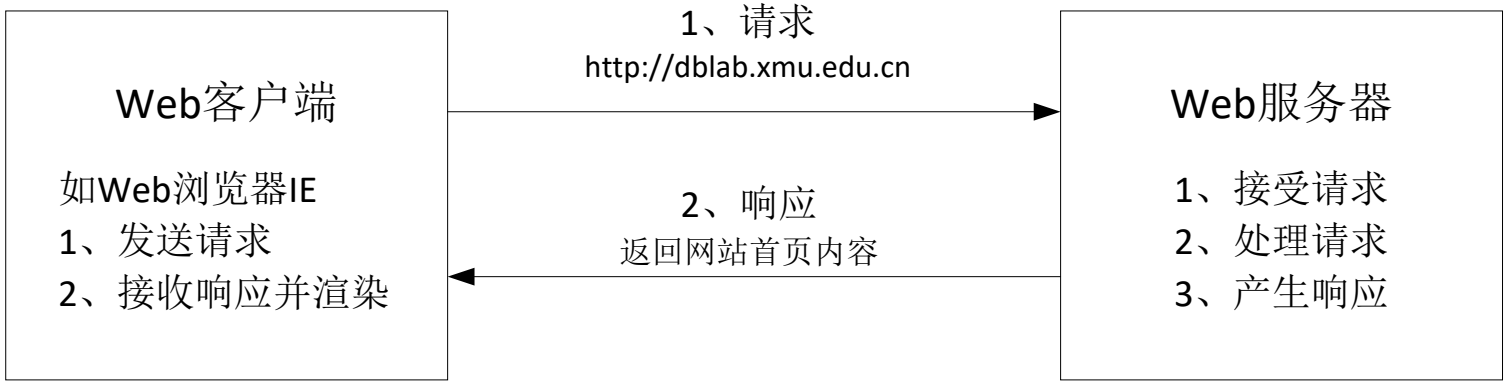

图3-3 一个典型的HTTP请求过程

3.3 用Python实现HTTP请求

3.3.1 urllib模块
3.3.2 urllib3模块
3.3.3 requests模块

3.3.1 urllib模块

urllib是Python自带模块，该模块提供了一个urlopen()方法，通过该方法指定URL发送HTTP请求来获取数据。urllib提供了多个子模块，具体的模块名称与功能如表3-1所示。

表3-1 urllib中的子模块

模块名称	功能
urllib.request	该模块定义了打开URL（主要是HTTP）的方法和类，如身份验证、重定向和cookie等
urllib.error	该模块中主要包含异常类，基本的异常类是URLError
urllib.parse	该模块定义的功能分为两大类：URL解析和URL引用
urllib.robotparser	该模块用于解析robots.txt文件

3.3.1 urllib模块

下面是通过urllib.request模块实现发送GET请求获取网页内容的实例：

```
>>> import urllib.request
>>> response=urllib.request.urlopen("http://www.baidu.com")
>>> html=response.read()
>>> print(html)
```

3.3.1 urllib模块

下面是通过urllib.request模块实现发送POST请求获取网页内容的实例：

```
    >>> import urllib.parse
>>> import urllib.request
>>> # 1.指定url
>>> url = 'https://fanyi.baidu.com/sug'
>>> # 2.发起POST请求之前，要处理POST请求携带的参数
>>> # 2.1 将POST请求封装到字典
>>> data = {'kw':'苹果',}
```

3.3.1 urllib模块

```
>>> # 2.2 使用parse模块中的urlencode(返回值类型是字符串类型)进行编码处理
>>> data = urllib.parse.urlencode(data)
>>> # 将步骤2.2的编码结果转换成byte类型
>>> data = data.encode()
>>> # 3.发起POST请求:urlopen函数的data参数表示的就是经过处理之后的POST请求携带的参数
>>> response = urllib.request.urlopen(url=url,data=data)
>>> data = response.read()
>>> print(data)
b'{"errno":0,"data":[{"k":"\\u82f9\\u679c","v":"\\u540d.
apple"},{"k":"\\u82f9\\u679c\\u56ed","v":"apple
grove"},{"k":"\\u82f9\\u679c\\u5934","v":"apple
head"},{"k":"\\u82f9\\u679c\\u5e72","v":"[\\u533b]dried
apple"},{"k":"\\u82f9\\u679c\\u6728","v":"applewood"}]}'
```

3.3.1 urllib模块

把上面print(data)执行的结果，拿到JSON在线格式校验网站（http://www.bejson.com/）进行处理，使用“Unicode转中文”功能可以得到如下结果：

b'{"errno":0,"data":[{"k":"\苹\果","v":"\名. apple"},{"k":"\苹\果\园","v":"apple grove"},{"k":"\苹\果\头","v":"apple head"},{"k":"\苹\果\干","v":"[\医]dried apple"},{"k":"\苹\果\木","v":"applewood"}]}'

3.3.2 urllib3模块

urllib3是一个功能强大、条理清晰、用于HTTP客户端的Python库，许多Python的原生系统已经开始使用urllib3。urllib3提供了很多python标准库里所没有的重要特性，包括：线程安全、连接池、客户端SSL/TLS验证、文件分部编码上传、协助处理重复请求和HTTP重定位、支持压缩编码、支持HTTP和SOCKS代理、100%测试覆盖率等。

在使用urllib3之前，需要打开一个cmd窗口使用如下命令进行安装：

```
> pip install urllib3
```

下面是通过GET请求获取网页内容的实例：

```
>>> import urllib3
>>> #需要一个PoolManager实例来生成请求，由该实例对象处理与线程池的连接以及线程安全的所有细节，不需要任何人为操作
>>> http = urllib3.PoolManager()
>>> response = http.request('GET','http://www.baidu.com')
>>> print(response.status)
>>> print(response.data)
```

3.3.2 urllib3模块

下面是通过POST请求获取网页内容的实例：

```
>>> import urllib3
>>> http = urllib3.PoolManager()
>>> response = http.request('POST',
                            'https://fanyi.baidu.com/sug'
                            ,fields={'kw':'苹果',})
>>> print(response.data)
```

3.3.3 requests模块

requests库是一个非常好用的HTTP请求库，可用于网络请求和网络爬虫等。

在使用requests之前，需要打开一个cmd窗口使用如下命令进行安装：

```
> pip install requests
```

以GET请求方式为例，打印多种请求信息的代码如下：

```
>>> import requests
>>> response = requests.get('http://www.baidu.com') #对需要爬取的网页发送请求
>>> print('状态码:',response.status_code) #打印状态码
>>> print('url:',response.url) #打印请求url
>>> print('header:',response.headers) #打印头部信息
>>> print('cookie:',response.cookies) #打印cookie信息
>>> print('text:',response.text) #以文本形式打印网页源码
>>> print('content:',response.content) #以字节流形式打印网页源码
```

3.3.3 requests模块

以POST请求方式发送HTTP网页请求的示例代码如下：

```
>>> import requests
>>> #导入模块
>>> import requests
>>> #表单参数
>>> data = {'kw':'苹果',}
>>> #对需要爬取的网页发送请求
>>> response =
requests.post('https://fanyi.baidu.com/sug',data=data)
>>> #以字节流形式打印网页源码
>>> print(response.content)
```

3.4 定制requests

3.4.1 传递URL参数
3.4.2 定制请求头
3.4.3 网络超时

3.4.1 传递URL参数

为了请求特定的数据，我们需要在URL（Uniform Resource Locator）的查询字符串中加入一些特定数据。这些数据一般会跟在一个问号后面，并且以键值对的形式放在URL中。在requests中，我们可以直接把这些参数保存在字典中，用params构建到URL中。具体实例如下：

```
>>> import requests
>>> base_url = 'http://httpbin.org'
>>> param_data = {'user':'xmu','password':'123456'}
>>> response = requests.get(base_url+'/get',params=param_data)
>>> print(response.url)
http://httpbin.org/get?user=xmu&password=123456
>>> print(response.status_code)
200
```

3.4.2 定制请求头

在爬取网页的时候，输出的信息中有时候会出现“抱歉，无法访问”等字眼，这就是禁止爬取，需要通过定制请求头Headers来解决这个问题。定制Headers是解决requests请求被拒绝的方法之一，相当于我们进入这个网页服务器，假装自己本身在爬取数据。请求头Headers提供了关于请求、响应或其他发送实体的消息，如果没有定制请求头或请求的请求头和实际网页不一致，就可能无法返回正确结果。

3.4.2 定制请求头

获取一个网页的Headers的方法如下：使用360、火狐或谷歌浏览器打开一个网址（比如“http://httpbin.org/”），在网页上单击鼠标右键，在弹出的菜单中选择“查看元素”，然后刷新网页，再按照如图3-4所示的步骤，先点击“Network”选项卡，再点击“Doc”，接下来点击“Name”下方的网址，就会出现类似如下的Headers信息：

User-Agent:Mozilla/5.0 (Windows NT 6.1; WOW64) AppleWebKit/537.36 (KHTML, like Gecko) Chrome/46.0.2490.86 Safari/537.36

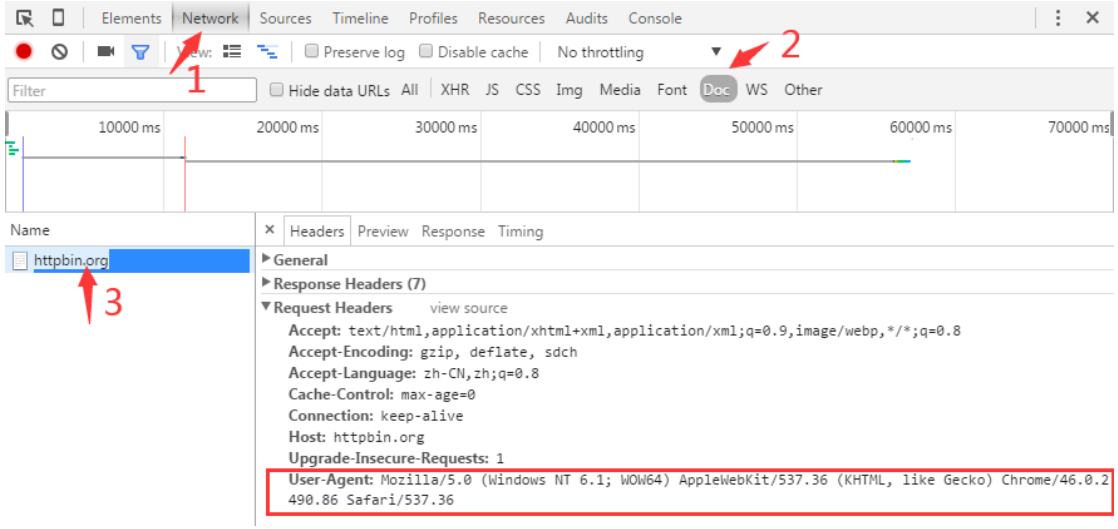

图3-4 查看请求头Headers

3.4.2 定制请求头

Headers中有很多内容，主要常用的就是“User-Agent”和“Host”，它们是以键对的形式呈现的，如果把“User-Agent”以字典键值对形式作为Headers的内容，往往就可以顺利爬取网页内容。

下面是添加了Headers信息的网页请求过程：

```
>>> import requests
>>> url='http://httpbin.org'
>>> # 创建头部信息
>>> headers={'User-Agent':'Mozilla/5.0 (Windows NT 6.1; WOW64) AppleWebKit/537.36 (KHTML, like Gecko) Chrome/46.0.2490.86 Safari/537.36'}
>>> response = requests.get(url,headers=headers)
>>> print(response.content)
```

3.4.3 网络超时

网络请求不可避免会遇上请求超时的情况，这个时候，网络数据采集的程序会一直运行等待进程，造成网络数据采集程序不能很好地顺利执行。因此，可以为requests的timeout参数设定等待秒数，如果服务器在指定时间内没有应答就返回异常。具体代码如下：

```
01  # time_out.py02  import requests03  from
requests.exceptions import ReadTimeout,ConnectTimeout04
try:05      response = requests.get("http://www.baidu.com",
timeout=0.5)06      print(response.status_code)07  except
ReadTimeout or ConnectTimeout:08      print('Timeout')
```

3.5解析网页

3.5.1 BeautifulSoup简介
3.5.2 BeautifulSoup四大对象
3.5.3遍历文档树
3.5.4 搜索文档树
3.5.5 CSS选择器

3.5.1 BeautifulSoup简介

BeautifulSoup提供一些简单的、Python式的函数来处理导航、搜索、修改分析树等。BeautifulSoup是一个工具箱，通过解析文档为用户提供需要抓取的数据，因为简单，所以不需要多少代码就可以写出一个完整的应用程序。BeautifulSoup自动将输入文档转换为Unicode编码，输出文档转换为UTF-8编码。BeautifulSoup3已经停止开发，目前推荐使用BeautifulSoup4，不过它已经被移植到bs4当中了，所以，在使用BeautifulSoup4之前，需要安装bs4：

```
> pip install bs4
```

3.5.1 BeautifulSoup简介

使用BeautifulSoup解析HTML比较简单，API非常人性化，支持CSS选择器、Python标准库中的HTML解析器，也支持lxml的XML解析器和HTML解析器，此外还支持html5lib解析器，表3-2给出了每个解析器的优缺点。

表3-2 不同解析器的优缺点比较

解析器	用法	优点	缺点
Python标准库	BeautifulSoup(markup,"html.parser")	Python标准库执行速度适中	文档容错能力差
lxml的HTML解析器	BeautifulSoup(markup,"lxml")	速度快文档容错能力强	需要安装C语言库
lxml的XML解析器	BeautifulSoup(markup, "lxml-xml") BeautifulSoup(markup,"xml")	速度快唯一支持XML的解析器	需要安装C语言库
html5lib	BeautifulSoup(markup, "html5lib")	兼容性好以浏览器的方式解析文档生成HTML5格式的文档	速度慢，不依赖外部扩展

3.5.1 BeautifulSoup简介

下面给出一个BeautifulSoup解析网页的简单实例，使用了lxml解析器，在使用之前，需要执行如下命令安装lxml解析器：

```
> pip install lxml
```

下面是实例代码：

```
>>> html_doc = """
<html><head><title>BigData Software</title></head>
<p class="title"><b>BigData Software</b></p>
<p class="bigdata">There are three famous bigdata softwares; and their names are
<a href="http://example.com/hadoop" class="software" id="link1">Hadoop</a>,
<a href="http://example.com/spark" class="software" id="link2">Spark</a> and
<a href="http://example.com/flink" class="software" id="link3">Flink</a>;
and they are widely used in real applications.</p>
<p class="bigdata">...</p>
"""
```

```
>>> from bs4 import BeautifulSoup
>>> soup = BeautifulSoup(html_doc,"lxml")
>>> content = soup.prettify()
>>> print(content)
<html>
 <head>
  <title>
   BigData Software
  </title>
 </head>
 <body>
  <p class="title">
   <b>
    BigData Software
   </b>
  </p>
  <p class="bigdata">
   There are three famous bigdata softwares; and their names are
   <a class="software" href="http://example.com/hadoop" id="link1">
    Hadoop
   </a>
   ,
   <a class="software" href="http://example.com/spark" id="link2">
    Spark
   </a>
   and
   <a class="software" href="http://example.com/flink" id="link3">
    Flink
   </a>
   ;
and they are widely used in real applications.
  </p>
  <p class="bigdata">
   ...
  </p>
 </body>
</html>
```

3.5.1 BeautifulSoup简介

如果要更换解析器，比如要使用Python标准库的解析器，只需要把上面的“soup = BeautifulSoup(html_doc,"lxml")”这行代码替换成如下代码即可：

```
soup = BeautifulSoup(html_doc,"html.parser")
```

3.5.2 BeautifulSoup四大对象

BeautifulSoup将复杂HTML文档转换成一个复杂的树形结构，每个节点都是Python对象，所有对象可以归纳为4种：Tag、NavigableString、BeautifulSoup、Comment。

Tag就是HTML中的一个个标签，例如：

```
<title>BigData Software</title><a href="http://example.com/hadoop"
class="software" id="link1">Hadoop</a>
```

上面的<title>、<a>等标签加上里面包括的内容就是Tag，利用soup加标签名可以轻松地获取这些标签的内容。作为演示，我们可以继续执行以下代码：

3.5.2 BeautifulSoup四大对象

```
>>> print(soup.a)
<a class="software" href="http://example.com/hadoop"
id="link1">Hadoop</a>
>>> print(soup.title)
<title>BigData Software</title>
```

Tag有两个重要的属性，即name和attrs。下面继续执行如下代码：

```
>>> print(soup.name)
[document]
>>> print(soup.p.attrs)
{'class': ['title']}
```

如果想要单独获取某个属性，比如要获取“class”属性的值，可以执行如下代码：

```
>>> print(soup.p['class'])
['title']
```

还可以利用get方法获得属性的值，代码如下：

```
>>> print(soup.p.get('class'))
['title']
```

3.5.2 BeautifulSoup四大对象

2. NavigableString

NavigableString对象用于操纵字符串。在网页解析时，已经得到了标签的内容以后，如果我们想获取标签内部的文字，则可以使用.string方法，其返回值就是一个NavigableString对象，具体实例如下：

```
>>> print(soup.p.string)
BigData Software
>>> print(type(soup.p.string))
<class 'bs4.element.NavigableString'>
```

3.5.2 BeautifulSoup四大对象

3. BeautifulSoup

BeautifulSoup对象表示的是一个文档的全部内容，大部分时候，可以把它当作Tag对象，是一个特殊的Tag。例如，可以分别获取它的类型、名称以及属性：

```
>>> print(type(soup.name))
<class 'str'>
>>> print(soup.name)
[document]
>>> print(soup.attrs)
{}
```

3.5.2 BeautifulSoup四大对象

4.Comment

Comment对象是一种特殊类型的NavigableString对象，输出的内容不包括注释符号。如果它处理不好，可能会对文本处理造成意想不到的麻烦。为了演示Comment对象，这里重新创建一个代码文件bs4_example.py：

3.5.2 BeautifulSoup四大对象

```
01  # bs4_example.py
02  html_doc = """
03  <html><head><title>The Dormouse's story</title></head>
04  <p class="title"><b>The Dormouse's story</b></p>
05  <p class="story">Once upon a time there were three little sisters; and their
names were
06  <a href="http://example.com/elsie" class="sister" id="link1"><!-- Elsie --></a>,
07  <a href="http://example.com/lacie" class="sister" id="link2">Lacie</a> and
08  <a href="http://example.com/tillie" class="sister" id="link3">Tillie</a>;
09  and they lived at the bottom of a well.</p>
10  <p class="story">...</p>
11  """
12  from bs4 import BeautifulSoup
13  soup = BeautifulSoup(html_doc,"lxml")
14  print(soup.a)
15  print(soup.a.string)
16  print(type(soup.a.string))
```

3.5.2 BeautifulSoup四大对象

该代码文件的执行结果如下：

```
<a class="sister"
href="http://example.com/elsie" id="link1"><!-
- Elsie --></a>
Elsie
<class 'bs4.element.Comment'>
```

从上面执行结果可以看出，a标签里的内容“<!-- Elsie -->”实际上是注释，但是使用语句print(soup.a.string)输出它的内容以后会发现，它已经把注释符号去掉了，只输出了“Elsie”，所以这可能会给我们带来不必要的麻烦。另外我们打印输出它的类型，发现它是一个Comment类型。

3.5.3遍历文档树

遍历文档树就是从根节点html标签开始遍历，直到找到目标元素为止。

1.直接子节点

（1）.contents属性

Tag对象的.contents属性可以将某个Tag的子节点以列表的方式输出，当然列表会允许用索引的方式来获取列表中的元素。下面是示例代码：

```
>>> html_doc = """
<html><head><title>BigData Software</title></head>
<p class="title"><b>BigData Software</b></p>
<p class="bigdata">There are three famous bigdata softwares; and their names are
<a href="http://example.com/hadoop" class="software" id="link1">Hadoop</a>,
<a href="http://example.com/spark" class="software" id="link2">Spark</a> and
<a href="http://example.com/flink" class="software" id="link3">Flink</a>;
and they are widely used in real applications.</p>
<p class="bigdata">...</p>
"""
```

3.5.3遍历文档树

```
>>> from bs4 import BeautifulSoup
>>> soup = BeautifulSoup(html_doc,"lxml")
>>> print(soup.body.contents)
[<p class="title"><b>BigData Software</b></p>, '\n', <p class="bigdata">There are three famous bigdata softwares; and their names are
<a class="software" href="http://example.com/hadoop" id="link1">Hadoop</a>,
<a class="software" href="http://example.com/spark" id="link2">Spark</a> and
<a class="software" href="http://example.com/flink" id="link3">Flink</a>;
and they are widely used in real applications.</p>, '\n', <p class="bigdata">...</p>, '\n']
```

3.5.3遍历文档树

可以使用索引的方式来获取列表中的元素：

```
>>> print(soup.body.contents[0])
<p class="title"><b>BigData Software</b></p>
```

3.5.3遍历文档树

（2）.children属性

Tag对象的.children属性是一个迭代器，可以使用for循环进行遍历，代码如下：

```
>>> for child in soup.body.children:
    print(child)
```

上面代码的执行结果如下：

```
<p class="title"><b>BigData Software</b></p>


<p class="bigdata">There are three famous bigdata softwares; and their names are
<a class="software" href="http://example.com/hadoop" id="link1">Hadoop</a>,
<a class="software" href="http://example.com/spark" id="link2">Spark</a> and
<a class="software" href="http://example.com/flink" id="link3">Flink</a>;
and they are widely used in real applications.</p>


<p class="bigdata">...</p>
```

3.5.3遍历文档树

2.所有子孙节点

在获取所有子孙节点时，可以使用.descendants属性，与Tag对象的.children和.contents仅包含Tag对象的直接子节点不同，该属性是将Tag对象的所有子孙结点进行递归循环，然后生成生成器。示例代码如下：

```
>>> for child in soup.descendants:
        print(child)
```

上面代码的执行结果较多，因此这里没有给出。在执行结果中可以发现，所有的节点都被打印出来了，先生成最外层的html标签，其次从head标签一个个剥离，依此类推。

3.5.3遍历文档树

3.节点内容

（1）Tag对象内没有标签的情况。

```
>>> print(soup.title)
<title>BigData Software</title>
>>> print(soup.title.string)
BigData Software
```

（2）Tag对象内有一个标签的情况。

```
>>> print(soup.head)
<head><title>BigData Software</title></head>
>>> print(soup.head.string)
BigData Software
```

3.5.3遍历文档树

（3）Tag对象内有多个标签的情况。

```
>>> print(soup.body)
<body><p class="title"><b>BigData Software</b></p>
<p class="bigdata">There are three famous bigdata softwares; and their names
are
<a class="software" href="http://example.com/hadoop" id="link1">Hadoop</a>,
<a class="software" href="http://example.com/spark" id="link2">Spark</a> and
<a class="software" href="http://example.com/flink" id="link3">Flink</a>;
and they are widely used in real applications.</p>
<p class="bigdata">...</p>
</body>
```

从上面的执行结果中可以看出，body标签内包含了多个p标签，这时如果使用.string获取子节点内容，就会返回None，代码如下：

```
>>> print(soup.body.string)
None
```

3.5.3遍历文档树

也就是说，如果Tag包含了多个子节点，Tag就无法确定.string应该调用哪个子节点的内容，因此.string的输出结果是None。这时应该使用.strings属性或.stripped_strings属性，它们获得的都是一个生成器，示例代码如下：

```
>>> print(soup.strings)
<generator object Tag._all_strings at 0x0000000002C4D190>
```

3.5.3遍历文档树

可以用for循环对生成器进行遍历，代码如下：

```
>>> for string in soup.strings:
      print(repr(string))
```

上面代码的执行结果如下：

```
   'BigData Software'
'\n'
'BigData Software'
'\n'
'There are three famous bigdata softwares; and their names are\n'
'Hadoop'
',\n'
'Spark'
' and\n'
'Flink'
';\nand they are widely used in real applications.'
'\n'
'...'
'\n'
```

3.5.3遍历文档树

使用Tag对象的.stripped_strings属性，可以获得去掉空白行的标签内的众多内容，示例代码如下：

```
>>> for string in soup.stripped_strings:
        print(string)
```

上面代码的执行结果如下：

```
BigData Software
BigData Software
There are three famous bigdata softwares; and their names are
Hadoop
,
Spark
and
Flink
;
and they are widely used in real applications.
...
```

3.5.3遍历文档树

4.直接父节点

使用Tag对象的.parent属性可以获得父节点，使用Tag对象的.parents属性可以获得从父到根的所有节点。

下面是标签的父节点：

```
>>> p = soup.p
>>> print(p.parent.name)
Body
```

下面是内容的父节点：

```
>>> content = soup.head.title.string
>>> print(content)
BigData Software
>>> print(content.parent.name)
title
```

3.5.3遍历文档树

Tag对象的.parents属性，得到的也是一个生成器：

```
>>> content = soup.head.title.string
>>> print(content)
BigData Software
>>> for parent in content.parents:
    print(parent.name)
```

上面语句的执行结果如下：

```
title
head
html
[document]
```

3.5.3遍历文档树

5.兄弟节点

可以使用Tag对象的.next_sibling和.previous_sibling属性分别获取下一个兄弟结点和获取上一个兄弟结点。需要注意的是，实际文档中Tag的.next_sibling和.previous_sibling属性通常是字符串或空白，因为空白或者换行也可以被视作一个节点，所以得到的结果可能是空白或者换行。示例代码如下：

```
>>> print(soup.p.next_sibling)
# 此处返回为空白
>>> print(soup.p.prev_sibling)
None  #没有前一个兄弟节点，返回None
>>> print(soup.p.next_sibling.next_sibling)
```

上面这个语句的返回结果如下：

```
<p class="bigdata">There are three famous bigdata softwares; and their names
are
<a class="software" href="http://example.com/hadoop" id="link1">Hadoop</a>,
<a class="software" href="http://example.com/spark" id="link2">Spark</a> and
<a class="software" href="http://example.com/flink" id="link3">Flink</a>;
and they are widely used in real applications.</p>
```

3.5.3遍历文档树

6.全部兄弟节点

可以使用Tag对象的.next_siblings和.previous_siblings属性对当前的兄弟结点迭代输出。示例代码如下：

```
>>> for next in soup.a.next_siblings:
    print(repr(next))
```

执行结果如下：

```
   ',\n'
<a class="software" href="http://example.com/spark"
id="link2">Spark</a>
' and\n'
<a class="software" href="http://example.com/flink" id="link3">Flink</a>
';\nand they are widely used in real applications.'
```

3.5.3遍历文档树

7.前后节点

Tag对象的.next_element和.previous_element属性，用于获得不分层次的前后元素，示例代码如下：

```
>>> print(soup.head.next_element)
<title>BigData Software</title>
```

3.5.3遍历文档树

8. 所有前后节点

使用Tag对象的.next_elements和.previous_elements属性可以向前或向后解析文档内容，示例代码如下：

```
>>> for element in soup.a.next_elements:
    print(repr(element))
```

执行结果如下：

```
   'Hadoop'
',\n'
<a class="software" href="http://example.com/spark"
id="link2">Spark</a>
'Spark'
' and\n'
<a class="software" href="http://example.com/flink" id="link3">Flink</a>
'Flink'
';\nand they are widely used in real applications.'
'\n'
<p class="bigdata">...</p>
'...'
'\n'
```

3.5.4 搜索文档树

搜索文档树是通过指定标签名来搜索元素，另外还可以通过指定标签的属性值来精确定位某个节点元素，最常用的两个方法就是find()和find_all()，这两个方法在BeatifulSoup和Tag对象上都可以被调用。

1.find_all()

find_all()方法搜索当前Tag的所有Tag子节点，并判断是否符合过滤器的条件，它的函数原型是：

```
find_all( name , attrs , recursive , text , **kwargs )
```

find_all()的返回值是一个Tag组成的列表，方法调用非常灵活，所有的参数都是可选的。

3.5.4 搜索文档树

（1）name参数

name参数可以查找所有名字为name的Tag，字符串对象会被自动忽略掉。

①传入字符串

查找所有名字为a的Tag，代码如下：

```
>>> print(soup.find_all('a'))
```

[Hadoop, Spark, Flink]

3.5.4 搜索文档树

②传入正则表达式

如果传入正则表达式作为参数，BeautifulSoup会通过正则表达式的match()来匹配内容.下面例子中找出所有以b开头的标签，这表示<body>和<b>标签都应该被找到：

```
>>> import re
>>> for tag in soup.find_all(re.compile("^b")):
    print(tag)
```

执行结果如下：

```
<body><p class="title"><b>BigData Software</b></p>
<p class="bigdata">There are three famous bigdata softwares; and their names are
<a class="software" href="http://example.com/hadoop" id="link1">Hadoop</a>,
<a class="software" href="http://example.com/spark" id="link2">Spark</a> and
<a class="software" href="http://example.com/flink" id="link3">Flink</a>;
and they are widely used in real applications.</p>
<p class="bigdata">...</p>
</body>
<b>BigData Software</b>
```

3.5.4 搜索文档树

③传入列表

如果传入参数是列表，BeautifulSoup会将与列表中任一元素匹配的内容返回。下面代码找到文档中所有<a>标签和<b>标签：

```
>>> print(soup.find_all(["a","b"]))
   [<b>BigData Software</b>, <a class="software"
href="http://example.com/hadoop" id="link1">Hadoop</a>, <a
class="software" href="http://example.com/spark"
id="link2">Spark</a>, <a class="software"
href="http://example.com/flink" id="link3">Flink</a>]
```

3.5.4 搜索文档树

④传入True

传入True可以找到所有的标签。下面的例子在文档树中查找所有包含id属性的标签，无论id的值是什么：

```
>>> print(soup.find_all(id=True))
   [<a class="software" href="http://example.com/hadoop"
id="link1">Hadoop</a>, <a class="software"
href="http://example.com/spark" id="link2">Spark</a>, <a
class="software" href="http://example.com/flink"
id="link3">Flink</a>]
```

3.5.4 搜索文档树

⑤传入方法

如果没有合适过滤器，那么还可以定义一个方法，方法只接受一个元素参数，如果这个方法返回True，表示当前元素匹配并且被找到，如果不是则返回False。下面方法对当前元素进行校验，如果包含class属性却不包含id属性，那么将返回True：

```
>>> def has_class_but_no_id(tag):
    return tag.has_attr('class') and not tag.has_attr('id')
```

将这个方法作为参数传入find_all()方法，将得到所有<p>标签：

```
>>> print(soup.find_all(has_class_but_no_id))
[<p class="title"><b>BigData Software</b></p>, <p class="bigdata">There are
three famous bigdata softwares; and their names are
<a class="software" href="http://example.com/hadoop" id="link1">Hadoop</a>,
<a class="software" href="http://example.com/spark" id="link2">Spark</a> and
<a class="software" href="http://example.com/flink" id="link3">Flink</a>;
and they are widely used in real applications.</p>, <p class="bigdata">...</p>]
```

3.5.4 搜索文档树

（2）keyword参数

通过name参数是搜索Tag的标签类型名称，如a、head、title等。如果要通过标签内属性的值来搜索，要通过键值对的形式来指定，实例如下：

```
>>> import re
>>> print(soup.find_all(id='link2'))
[<a class="software" href="http://example.com/spark" id="link2">Spark</a>]
>>> print(soup.find_all(href=re.compile("spark")))
[<a class="software" href="http://example.com/spark" id="link2">Spark</a>]
```

使用多个指定名字的参数可以同时过滤Tag的多个属性：

```
>>> soup.find_all(href=re.compile("hadoop"), id='link1')
[<a class="software" href="http://example.com/hadoop"
id="link1">Hadoop</a>]
```

如果指定的key是Python的关键词，则后面需要加下划线：

```
>>> print(soup.find_all(class_="software"))
[<a class="software" href="http://example.com/hadoop"
id="link1">Hadoop</a>, <a class="software"
href="http://example.com/spark" id="link2">Spark</a>, <a class="software"
href="http://example.com/flink" id="link3">Flink</a>]
```

3.5.4 搜索文档树

（3）text参数

text参数的作用和name参数类似，但是text参数的搜索范围是文档中的字符串内容（不包含注释），并且是完全匹配，当然也接受正则表达式、列表、True。实例如下：

```
>>> import re
>>> print(soup.a)
<a class="software" href="http://example.com/hadoop"
id="link1">Hadoop</a>
>>> print(soup.find_all(text="Hadoop"))
['Hadoop']
>>> print(soup.find_all(text=["Hadoop", "Spark", "Flink"]))
['Hadoop', 'Spark', 'Flink']
>>> print(soup.find_all(text="bigdata"))
[]
>>> print(soup.find_all(text="BigData Software"))
['BigData Software', 'BigData Software']
>>> print(soup.find_all(text=re.compile("bigdata")))
['There are three famous bigdata softwares; and their names are\n']
```

3.5.4 搜索文档树

（4）limit参数

可以通过limit参数来限制使用name参数或者attrs参数过滤出来的条目的数量，实例如下：

```
>>> print(soup.find_all("a"))
[<a class="software" href="http://example.com/hadoop"
id="link1">Hadoop</a>, <a class="software"
href="http://example.com/spark" id="link2">Spark</a>, <a class="software"
href="http://example.com/flink" id="link3">Flink</a>]
>>> print(soup.find_all("a",limit=2))
[<a class="software" href="http://example.com/hadoop"
id="link1">Hadoop</a>, <a class="software"
href="http://example.com/spark" id="link2">Spark</a>]
```

3.5.4 搜索文档树

（5）recursive 参数

调用Tag的find_all()方法时，BeautifulSoup会检索当前Tag的所有子孙节点，如果只想搜索Tag的直接子节点，可以使用参数recursive=False，实例如下：

```
>>> print(soup.body.find_all("a",recursive=False))
[]
```

在这个例子中，a标签都是在p标签内的，所以在body的直接子节点下搜索a标签是无法匹配到a标签的。

2.find()

find()与find_all()的区别是，find_all()将所有匹配的条目组合成一个列表，而find()仅返回第一个匹配的条目，除此以外，二者的用法都相同。

3.5.5 CSS选择器

BeautifulSoup支持大部分的CSS选择器，在Tag或BeautifulSoup对象的select()方法中传入字符串参数，即可使用CSS选择器的语法找到标签。

①通过标签名查找

```
>>> print(soup.select('title'))
[<title>BigData Software</title>]
>>> print(soup.select('a'))
[<a class="software" href="http://example.com/hadoop"
id="link1">Hadoop</a>, <a class="software"
href="http://example.com/spark" id="link2">Spark</a>, <a class="software"
href="http://example.com/flink" id="link3">Flink</a>]
>>> print(soup.select('b'))
[<b>BigData Software</b>]
```

3.5.5 CSS选择器

②通过类名查找

```
>>> print(soup.select('.software'))
[<a class="software" href="http://example.com/hadoop"
id="link1">Hadoop</a>, <a class="software"
href="http://example.com/spark" id="link2">Spark</a>, <a
class="software" href="http://example.com/flink" id="link3">Flink</a>]
```

③通过id名查找

```
>>> print(soup.select('#link1'))
[<a class="software" href="http://example.com/hadoop"
id="link1">Hadoop</a>]
```

3.5.5 CSS选择器

④组合查找

```
>>> print(soup.select('p #link1'))
[<a class="software" href="http://example.com/hadoop"
id="link1">Hadoop</a>]
>>> print(soup.select("head > title"))
[<title>BigData Software</title>]
>>> print(soup.select("p > a:nth-of-type(1)"))
[<a class="software" href="http://example.com/hadoop"
id="link1">Hadoop</a>]
>>> print(soup.select("p > a:nth-of-type(2)"))
[<a class="software" href="http://example.com/spark" id="link2">Spark</a>]
>>> print(soup.select("p > a:nth-of-type(3)"))
[<a class="software" href="http://example.com/flink" id="link3">Flink</a>]
```

在上面的语句中，"p > a:nth-of-type(2)"的含义是：p元素是某个父元素的子元素，选择子元素p，且子元素p必须是其父元素下的第二个p元素。

3.5.5 CSS选择器

⑤属性查找

查找时还可以加入属性元素，属性需要用中括号括起来，注意属性和标签属于同一节点，所以中间不能加空格，否则会无法匹配到。

```
>>> print(soup.select('a[class="software"]'))
[<a class="software" href="http://example.com/hadoop"
id="link1">Hadoop</a>, <a class="software"
href="http://example.com/spark" id="link2">Spark</a>, <a class="software"
href="http://example.com/flink" id="link3">Flink</a>]
>>> print(soup.select('a[href="http://example.com/hadoop"]'))
[<a class="software" href="http://example.com/hadoop"
id="link1">Hadoop</a>]
   >>> print(soup.select('p a[href="http://example.com/hadoop"]'))
   [<a class="software" href="http://example.com/hadoop"
id="link1">Hadoop</a>]
```

3.5.5 CSS选择器

以上的select方法返回的结果都是列表形式，可以以遍历的形式进行输出，然后用 get_text()方法来获取它的内容，实例如下：

```
>>> print(type(soup.select('title')))
<class 'bs4.element.ResultSet'>
>>> print(soup.select('title')[0].get_text())
BigData Software
>>> for title in soup.select('title'):
    print(title.get_text())
```

上面语句的执行结果如下：

```
BigData Software
```

3.6 综合实例

3.6.1 采集网页数据并解析成指定的格式
3.6.2 采集网页数据保存到文本文件
3.6.3 采集网页数据保存到MySQL数据库

3.6.1 采集网页数据并解析成指定的格式

采集百度实时热点网页（http://top.baidu.com/buzz?b=1&fr=20811）上的数据，并解析成指定的格式显示到屏幕上。可以打开一个浏览器，访问要爬取的网页，然后在浏览器中查看网页源代码，在源代码中找到搜索指数、排名、标题所在的位置，总结出它们共同的特征，就可以将它们全部提取出来了，具体实现代码如下：

```
01  # baidu_hot.py
02  import requests
03  from bs4 import BeautifulSoup
04
05  # 请求网页
06  def request_page(url,headers):
07      response = requests.get(url,headers=headers)
08      response.encoding =
response.apparent_encoding
09      return response.text
10
```

3.6.1 采集网页数据并解析成指定的格式

```
11 # 解析网页
12 def parse_page(html):
13     soup = BeautifulSoup(html,'html.parser')
14     all_topics=soup.find_all('tr')[1:]
15     for each_topic in all_topics:
16         topic_times = each_topic.find('td',class_='last')   #搜索指数
17         topic_rank = each_topic.find('td',class_='first')   #排名
18         topic_name = each_topic.find('td',class_='keyword')  #标题
19         if topic_rank != None and topic_name!=None and topic_times!=None:
20             topic_rank = each_topic.find('td',class_='first').get_text().replace(' ','').replace('\n','')
21             topic_name = each_topic.find('td',class_='keyword').get_text().replace('
','').replace('\n','')
22             topic_times = each_topic.find('td',class_='last').get_text().replace(' ','').replace('\n','')
23             tplt = "排名：{0:^4}\t标题：{1:{3}^15}\t热度：{2:^8}"
24             print(tplt.format(topic_rank,topic_name,topic_times,chr(12288)))
25
26 if __name__=='__main__':
27     url = 'http://top.baidu.com/buzz?b=1&fr=20811'
28     headers = {'User-Agent':'Mozilla/5.0'}
29     html = request_page(url,headers)
30     parse_page(html)
```

3.6.2 采集网页数据保存到文本文件

访问古诗文网站（https://so.gushiwen.org/mingju/），会显示如图3-5所示的页面，里面包含了很多名句，点击某一个名句（比如“山有木兮木有枝，心悦君兮君不知”），就会出现完整的古诗（如图3-6所示）。

图3-5 名句页面

3.6.2 采集网页数据保存到文本文件

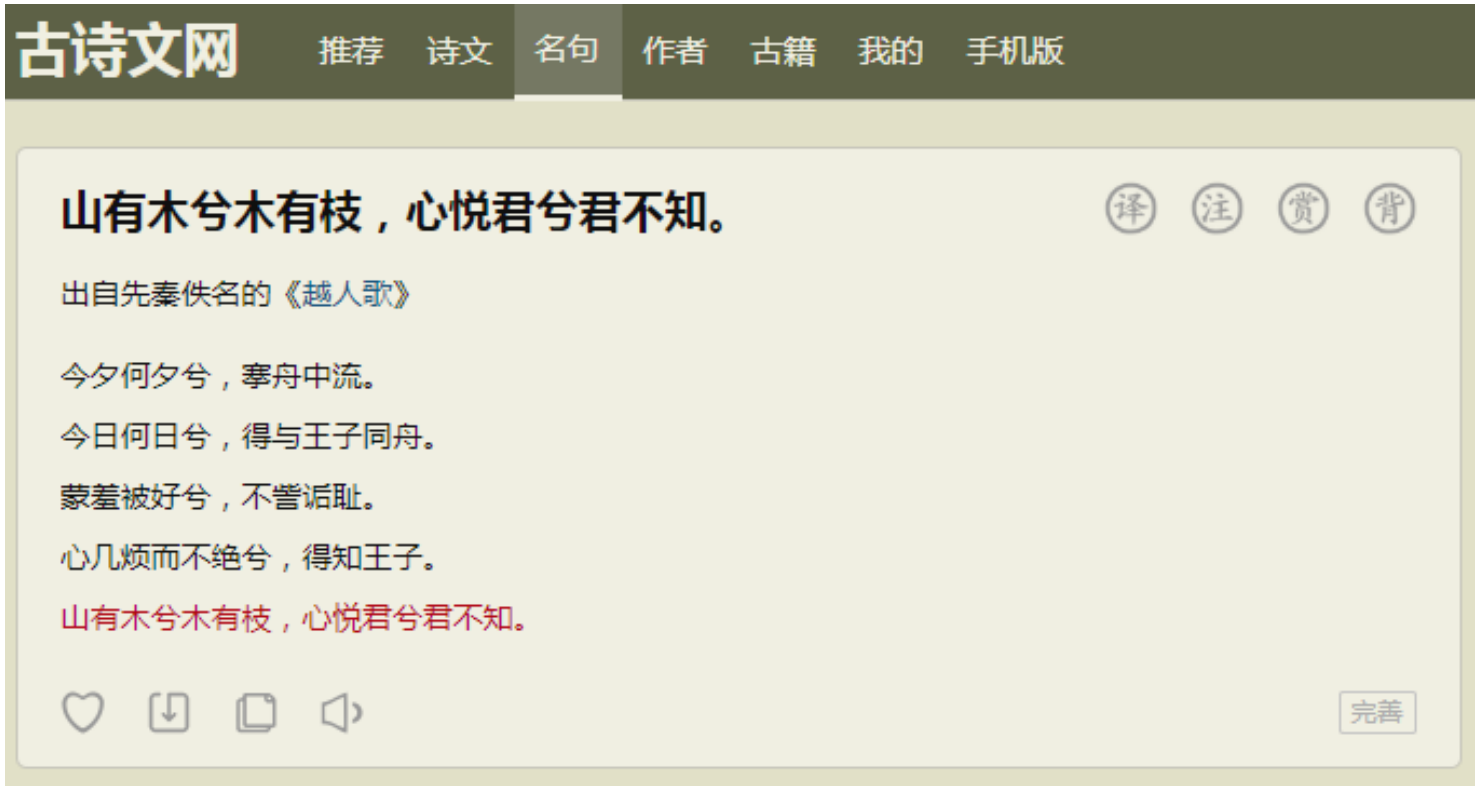

图3-6 完整古诗页面

3.6.2 采集网页数据保存到文本文件

下面编写网络爬虫程序，爬取名句页面的内容，保存到一个文本文件中，然后，再爬取每个名句的完整古诗页面，把完整古诗保存到一个文本文件中。可以打开一个浏览器，访问要爬取的网页，然后在浏览器中查看网页源代码，找到诗句内容所在的位置，总结出它们共同的特征，就可以将它们全部提取出来了，具体实现代码如下：

```
01 #parse_poem.py
02 import requests
03 from bs4 import BeautifulSoup
04 import time
05
06 #函数1：请求网页
07 def page_request(url,ua):
08     response = requests.get(url,headers = ua)
09     html = response.content.decode('utf-8')
10     return html
11
```

3.6.2 采集网页数据保存到文本文件

```
12 #函数2：解析网页
13 def page_parse(html):
14     soup = BeautifulSoup(html,'lxml')
15     title = soup('title')
16     sentence = soup.select('div.left > div.sons > div.cont > a:nth-of-
type(1)')
17     poet = soup.select('div.left > div.sons > div.cont > a:nth-of-
type(2)')
18     sentence_list=[]
19     href_list=[]
20     for i in range(len(sentence)):
21         temp = sentence[i].get_text()+ "---"+poet[i].get_text()
22         sentence_list.append(temp)
23         href = sentence[i].get('href')
24         href_list.append("https://so.gushiwen.org"+href)
25     return [href_list,sentence_list]
26
```

3.6.2 采集网页数据保存到文本文件

```
27 #函数3：写入文本文件
28 def save_txt(info_list):
29     import json
30     with open(r'C:\\sentence.txt','a',encoding='utf-8') as txt_file:
31         for element in info_list[1]:
32
txt_file.write(json.dumps(element,ensure_ascii=False)+'\n\n')
33
34 #子网页处理函数：进入并解析子网页/请求子网页
35 def sub_page_request(info_list):
36     subpage_urls = info_list[0]
37     ua = {'User-Agent':'Mozilla/5.0 (Windows NT 6.1; WOW64)
AppleWebKit/537.36 (KHTML, like Gecko) Chrome/46.0.2490.86
Safari/537.36'}
38     sub_html = []
39     for url in subpage_urls:
40         html = page_request(url,ua)
41         sub_html.append(html)
42     return sub_html
43
```

3.6.2 采集网页数据保存到文本文件

```
44 #子网页处理函数：解析子网页，爬取诗句内容
45 def sub_page_parse(sub_html):
46     poem_list=[]
47     for html in sub_html:
48         soup = BeautifulSoup(html,' lxml ')
49         poem = soup.select('div.left > div.sons > div.cont > div.contson')
50         poem = poem[0].get_text()
51         poem_list.append(poem.strip())
52     return poem_list
53
54 #子网页处理函数：保存诗句到txt
55 def sub_page_save(poem_list):
56     import json
57     with open(r'C:\\poems.txt','a',encoding='utf-8') as txt_file:
58         for element in poem_list:
59             txt_file.write(json.dumps(element,ensure_ascii=False)+'\n\n')
60
```

3.6.2 采集网页数据保存到文本文件

```
61  if __name__ == '__main__':
62      print("****************开始爬取古诗文网站*****************")
63      ua = {'User-Agent':'Mozilla/5.0 (Windows NT 6.1; WOW64) AppleWebKit/537.36
(KHTML, like Gecko) Chrome/46.0.2490.86 Safari/537.36'}
64      for i in range(1,4):
65          url = 'https://so.gushiwen.org/mingju/default.aspx?p=%d&c=&t='%(i)
66          time.sleep(1)
67          html = page_request(url,ua)
68          info_list = page_parse(html)
69          save_txt(info_list)
70          #处理子网页
71          print("开始解析第%d"%(i)+"页")
72          #开始解析名句子网页
73          sub_html = sub_page_request(info_list)
74          poem_list = sub_page_parse(sub_html)
75          sub_page_save(poem_list)
76
77      print("******************爬取完成**********************")
78      print("共爬取%d"%(i*50)+"个古诗词名句，保存在如下路径：
C:\\sentence.txt")
79      print("共爬取%d"%(i*50)+"个古诗词，保存在如下路径：C:\\poem.txt")
```

3.6.3 采集网页数据保存到MySQL数据库

由于很多网站设计了反爬机制，会导致爬取网页失败，因此，这里直接采集一个本地网页文件web_demo.html，它记录了不同关键词的搜索次数排名，其内容如下：

```
<html>
<head><title>搜索指数</title></head>
<body>
<table>
<tr><td>排名</td><td>关键词</td><td>搜索指数</td></tr>
<tr><td>1</td><td>大数据</td><td>187767</td></tr>
<tr><td>2</td><td>云计算</td><td>178856</td></tr>
<tr><td>3</td><td>物联网</td><td>122376</td></tr>
</table>
</body>
</html>
```

3.6.3 采集网页数据保存到MySQL数据库

参照第2章的内容，在Windows系统中启动MySQL服务进程，打开MySQL命令行客户端，执行如下SQL语句创建数据库和表：

```
mysql > CREATE DATABASE webdb;
mysql > USE webdb;
mysql > CREATE TABLE search_index
mysql> create table search_index(
    -> id int,
    -> keyword char(20),
    -> number int);
```

3.6.3 采集网页数据保存到MySQL数据库

编写网络爬虫程序，读取网页内容进行解析，并把解析后的数据保存到MySQL数据库中，具体代码如下：

```
01 # html_to_mysql.py
02 import requests
03 from bs4 import BeautifulSoup
04
05 # 读取本地HTML文件
06 def get_html():
07     path = 'C:/web_demo.html'
08     htmlfile= open(path,'r')
09     html = htmlfile.read()
10     return html
11
```

3.6.3 采集网页数据保存到MySQL数据库

```
12 # 解析HTML文件
13 def parse_html(html):
14     soup = BeautifulSoup(html,'html.parser')
15     all_tr=soup.find_all('tr')[1:]
16     all_tr_list = []
17     info_list = []
18     for i in range(len(all_tr)):
19         all_tr_list.append(all_tr[i])
20     for element in all_tr_list:
21         all_td=element.find_all('td')
22         all_td_list = []
23         for j in range(len(all_td)):
24             all_td_list.append(all_td[j].string)
25         info_list.append(all_td_list)
26     return info_list
27
```

3.6.3 采集网页数据保存到MySQL数据库

```
28 # 保存数据库
29 def save_mysql(info_list):
30     import pymysql.cursors
31     # 连接数据库
32     connect = pymysql.Connect(
33         host='localhost',
34         port=3306,
35         user='root', # 数据库用户名
36         passwd='123456', # 密码
37         db='webdb',
38         charset='utf8'
39     )
40
```

3.6.3 采集网页数据保存到MySQL数据库

```
41      # 获取游标
42      cursor = connect.cursor()
43
44      # 插入数据
45      for item in info_list:
46          id = int(item[0])
47          keyword = item[1]
48          number = int(item[2])
49          sql = "INSERT INTO search_index(id,keyword,number) VALUES ('%d',
'%s', %d)"
50          data = (id,keyword,number)
51          cursor.execute(sql % data)
52          connect.commit()
53      print('成功插入数据')
54
55      # 关闭数据库连接
56      connect.close()
57
58  if __name__ =='__main__':
59      html = get_html()
60      info_list = parse_html(html)
61      save_mysql(info_list)
```

3.6.3 采集网页数据保存到MySQL数据库

执行代码文件，然后到MySQL命令行客户端执行如下SQL语句查看数据：

mysql> select * from search_index;

可以看到，有3条数据被成功插入了数据库中。

```
mysql> select * from search_index;
+-------+----------+---------+
| id    | keyword  | number  |
+-------+----------+---------+
|     1 | 大数据   | 187767  |
|     2 | 云计算   | 178856  |
|     3 | 物联网   | 122376  |
+-------+----------+---------+
3 rows in set (0.21 sec)
```

3.7 Scrapy爬虫

3.7.1 Scrapy爬虫概述
3.7.2 XPath语言
3.7.3 Scrapy爬虫实例

3.7.1 Scrapy爬虫概述

Scrapy是一套基于Twisted的异步处理框架，是纯Python实现的爬虫框架，用户只需要定制开发几个模块就可以轻松地实现一个爬虫，用来抓取网页内容或者各种图片。Scrapy运行于Linux/Windows/MacOS等多种环境，具有速度快、扩展性强、使用简便等特点。即便是新手，也能迅速学会使用Scrapy编写所需要的爬虫程序。Scrapy可以在本地运行，也能部署到云端实现真正的生产级数据采集系统。Scrapy用途广泛，可以用于数据挖掘、监测和自动化测试。

1．Scrapy体系架构

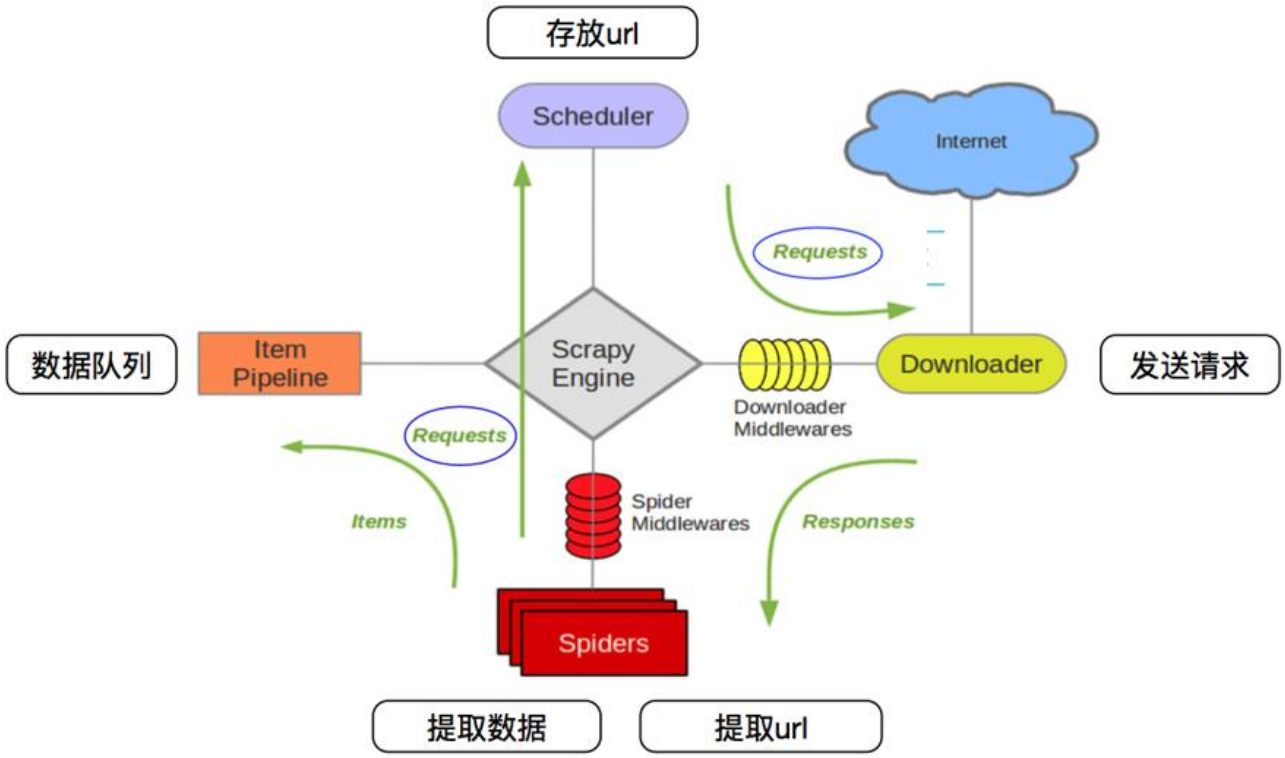

图3-7 Scrapy体系架构

2．Scrapy工作流

Scrapy工作流也叫作“运行流程”或叫作“数据处理流程”，整个数据处理流程由Scrapy引擎进行控制，其主要的运行步骤如下：

①Scrapy引擎从调度器中取出一个链接（URL）用于接下来的抓取；

②Scrapy引擎把URL封装成一个请求并传给下载器；

③下载器把资源下载下来，并封装成应答包；

④爬虫解析应答包；

⑤如果解析出的是项目，则交给项目管道进行进一步的处理；

⑥如果解析出的是链接（URL），则把URL交给调度器等待抓取。

3.7.2 XPath语言

XPath（XML Path Language）是一门在XML和HTML文档中查找信息的语言，可用来在XML和HTML文档中对元素和属性进行遍历。简单来说，网页数据是以超文本的形式来呈现的，想要获取里面的数据，就要按照一定的规则来进行数据的处理，这种规则就叫做XPath。XPath提供了超过100个内建函数，几乎所有要定位的节点都可以用XPath来定位，在做网络爬虫时可以使用XPath提取所需的信息。

3.7.2 XPath语言

1．基本术语

XML文档通常可以被看作一棵节点树。在XML中，有元素、属性、文本、命名空间、处理指令、注释以及文档节点等七种类型的节点，其中，元素节点是最常用的节点。下面是一个HTML文档中的代码：

```
<html>
   <head><title>BigData Software</title></head>
   <p class="title"><b>BigData Software</b></p>
   <p class="bigdata">There are three famous bigdata software;and their names
are
      <a href="http://example.com/hadoop" class="hadoop"
id="link1">Hadoop</a>,
      <a href="http://example.com/spark" class="spark" id="link2">Spark</a>and
      <a href="http://example.com/flink" class="flink" id="link3"><!--Flink--></a>;
      and they are widely used in real application.</p>
   <p class="bigdata">...</p>
</html>
```

3.7.2 XPath语言

上面的HTML文档中，<html>是文档节点，<title>BigData Software</title>是元素节点，class="title"是属性节点。节点之间存在下面几种关系：

（1）父节点：每个元素和属性都有一个父节点。例如，html节点是head节点和p节点的父节点；head节点是title节点的父节点；第二个p节点是中间三个a节点的父节点。

（2）子节点：每一个元素节点的下一个直接节点是该元素节点的子节点。每个元素节点可以有零个、一个或多个子节点。例如，title节点是head节点的子节点。

（3）兄弟节点：拥有相同父节点的节点，就是兄弟节点。例如，第二个p节点中的三个a节点就是兄弟节点；head节点和中间三个p节点就是兄弟节点；title节点和a节点就不是兄弟节点，因为不是同一个父节点。

（4）祖先节点：节点的父节点以及父节点的父节点等，称作“祖先节点”。例如，html节点和head节点是title节点的祖先节点。

（5）后代节点：节点的子节点以及子节点的子节点等，称作“后代节点”。例如，html节点的后代节点有head、title、b、p以及a节点。

3.7.2 XPath语言

2．基本语法

XML/HTML文档是由标签构成的，所有的标签都有很强的层级关系。基于这种层级关系，XPath语法能够准确定位我们所需要的信息。XPath使用路径表达式来选取XML/HTML文档中的节点，这个路径表达式和普通计算机文件系统中见到的路径表达式非常相似。在XPath语法中，我们直接使用路径来选取，再加上适当的谓语或函数进行指定，就可以准确定位到指定的节点。

3.7.2 XPath语言

（1）节点选取

XPath选取节点时，是沿着路径到达目标，表3-3列出了常用的表达式。

表3-3 常用表达式

表达式	描述
nodename	选取nodename节点的所有子节点
/	从根节点开始选取
//	从当前文档选取所有匹配的节点，而不考虑它们的位置
@	选取属性
.	选取当前节点
..	选取当前节点的父节点

3.7.2 XPath语言

“/”可以理解为绝对路径，需要从根节点开始；“./”则是相对路径，可以从当前节点开始；“../”则是先返回上一节点，从上一节点开始。这与普通计算机的文件系统类似。下面给出测试这些表达式的简单实例，这里需要用到lxml中的etree库，在使用之前需要执行如下命令安装lxml库：

```
> pip install lxm
```

3.7.2 XPath语言

下面是实例代码：

```
>>> html_text = """
<html>
 <body>
  <head><title>BigData Software</title></head>
  <p class="title"><b>BigData Software</b></p>
  <p class="bigdata">There are three famous bigdata software;and their names are
   <a href="http://example.com/hadoop" class="bigdata Hadoop"
id="link1">Hadoop</a>,
   <a href="http://example.com/spark" class="bigdata Spark"
id="link2">Spark</a>and
   <a href="http://example.com/flink" class="bigdata Flink" id="link3"><!--Flink--></a>;
    and they are widely used in real application.</p>
  <p class="bigdata">others</p>
       <p>……</p>
 </body>
</html>
"""
>>> from lxml import etree
>>> html = etree.HTML(html_text)
>>> html_data = html.xpath('body')
>>> print(html_data)
[<Element body at 0x1608dda2d80>]
```

3.7.2 XPath语言

可以看出，html.xpath('body')的输出结果不是像HTML里面那样显示的标签，其实这就是我们所要的元素，只不过我们还需要再进行一步操作，也就是使用etree中的.tostring()方法将其进行转换。此外，html.xpath('body')的输出结果是一个列表，因此，我们可以使用for循环来遍历列表，具体代码如下：

```
>>> for element in html_data:
        print(etree.tostring(element))
```

由于输出结果比较繁杂，这里没有给出，但是观察结果可以发现，它是标签<body>中的子节点。

3.7.2 XPath语言

“//”表示全局搜索，比如，“//p”可以将所有的<p>标签搜索出来。“/”表示在某标签下进行搜索，只能搜索子节点，不能搜索子节点的子节点。简单来说，“//”可以进行跳级搜索，“/”只能在本级上进行搜索，不能跳跃。下面是具体实例：

（1）逐级搜索

```
>>> html_data = html.xpath('/html/body/p/a')
>>> for element in html_data:
        print(etree.tostring(element))
```

（2）跳级搜索

```
>>> html_data = html.xpath('//a')
>>> for element in html_data:
        print(etree.tostring(element))
```

3.7.2 XPath语言

上面两段代码的执行结果相同，具体如下：

b'Hadoop,\n '

b'Sparkand\n '

b'<!--Flink-->;\n and they are widely used in real application.'

3.7.2 XPath语言

可以在方括号内添加“@”，将标签属性填进去，这样就可以准确地将含有该标签属性的部分提取出来，示例代码如下：

```
>>> html_data = html.xpath('//p/a[@class="bigdata Spark"]')
>>> for element in html_data:
        print(etree.tostring(element))
```

上面代码的执行结果如下：

```
b'<a href="http://example.com/spark" class="bigdata Spark"
id="link2">Spark</a>and\n '
```

3.7.2 XPath语言

（2）谓语

直接使用前面介绍的方法可以定位到多数我们需要的节点，但是有时候我们需要查找某个特定的节点或者包含某个指定值的节点，就要用到谓语。谓语是被嵌在方括号中的。表3-4列出了一些带有谓语的路径表达式及其描述的内容。

表3-4 带有谓语的路径表达式实例

路径表达式	描述
//body/p[k]	选取所有body下第k个p标签（k取值从1开始）
//body/p[last()]	选取所有body下最后一个p标签
//body/p[last()-1]	选取所有body下倒数第二个p标签
//body/p[position()<3]	选取所有body下的前两个p标签
//body/p[@class]	选取所有body下带有class属性的p标签
//body/p[@class="bigdata"]	选取所有body下，class为bigdata的p标签

3.7.2 XPath语言

下面演示表3-4中的最后一个例子，选取所有body下，class为bigdata的p标签，代码如下：

```
>>> html_data = html.xpath('//body/p[@class="bigdata"]')
>>> for element in html_data:
        print(etree.tostring(element))
```

上面代码执行结果如下：

```
b'<p class="bigdata">There are three famous bigdata software;and their names are\n
<a href="http://example.com/hadoop" class="bigdata Hadoop" id="link1">Hadoop</a>,\n
<a href="http://example.com/spark" class="bigdata Spark" id="link2">Spark</a>and\n
<a href="http://example.com/flink" class="bigdata Flink" id="link3"><!--Flink--></a>;\n
and they are widely used in real application.</p>\n  '
b'<p class="bigdata">...</p>\n  '
```

3.7.2 XPath语言

（3）函数

XPath中提供超过100个内建函数用于字符串值、数值、日期和时间比较序列处理等操作，极大地方便了我们定位获取所需要的信息。表3-5列出了几个常用的函数。

表3-5常用函数

函数名	描述	示例	说明
contains()	选取属性或文本包含某些字符	//p[contains(@class, "bigdata")]	选取所有class属性包含bigdata的p标签
starts-with()	选择属性或文本以某些字符开头	//a[starts-with(@class, "bigdata")]	选取所有class属性以bigdata开头的a标签
ends-with()	选取属性或文本以某些字符结尾	//a[ends-with(@class, "Flink")]	选取所有class属性以Flink结尾的a标签
text()	获取元素节点包含的文本内容	//a[contains(@class, "Hadoop")]/text()	获取所有class属性包含Hadoop的a标签中的文本内容

3.7.2 XPath语言

下面是示例代码，获取所有class属性包含bigdata的a标签中的文本内容，代码如下：

```
>>> html = etree.HTML(html_text)
>>> html_data = html.xpath('//a[contains(@class, "bigdata")]/text()')
>>> print(html_data)
['Hadoop', 'Spark']
```

在演示的HTML代码中，还有一个a标签也符合代码的要求，但是因为其文本内容是注释，所以不会被抽取出来显示。

3.7.3 Scrapy爬虫实例

访问古诗文网站（https://so.gushiwen.cn/mingjus/），使用Scrapy框架编写爬虫程序，爬取每个名句及其完整古诗内容，并把爬取到的数据分别保存到文本文件和MySQL数据库中。本实例需要使用开发工具PyCharm (Community Edition)，请到PyCharm官网（https://www.jetbrains.com/pycharm/download/）或本书官网的“下载专区”中下载PyCharm安装文件并安装。

本实例包括以下几个步骤：

- 新建工程；
- 编写代码文件items.py；
- 编写爬虫文件；
- 编写代码文件pipelines.py；
- 编写代码文件settings.py；
- 运行程序；

把数据保存到数据库中。

3.7.3 Scrapy爬虫实例

1.新建工程

在PyCharm中新建一个名称为“scrapyProject”的工程。在“scrapyProject”工程底部打开Terminal窗口（如图3-8所示），在命令提示符后面输入命令“pip install scrapy”，下载Scrapy框架所需文件。

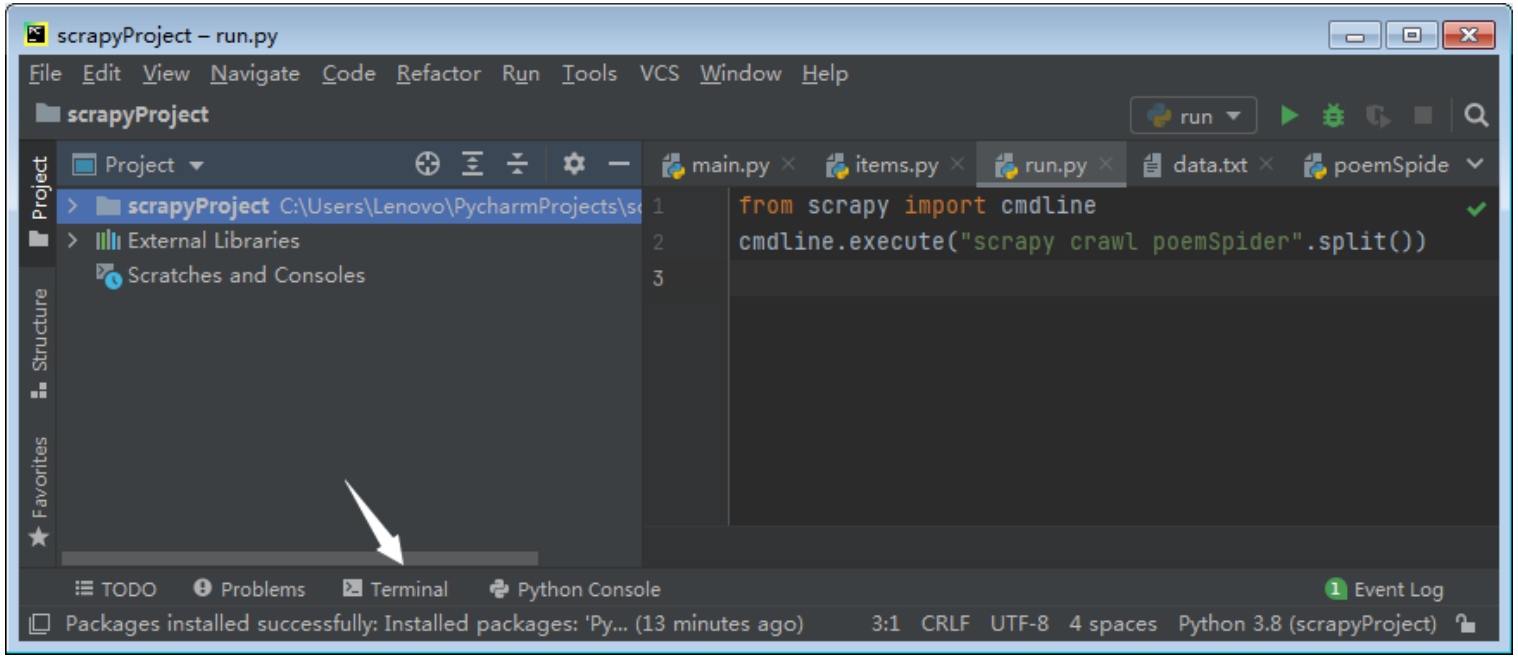

图3-8 打开Terminal窗口

3.7.3 Scrapy爬虫实例

下载完成后，继续输入命令“scrapy startproject poemScrapy”，创建Scrapy爬虫框架相关目录和文件。创建完成以后的具体目录结构如图3-9所示，这些目录和文件都是由Scrapy框架自动创建的，不需要手动创建。

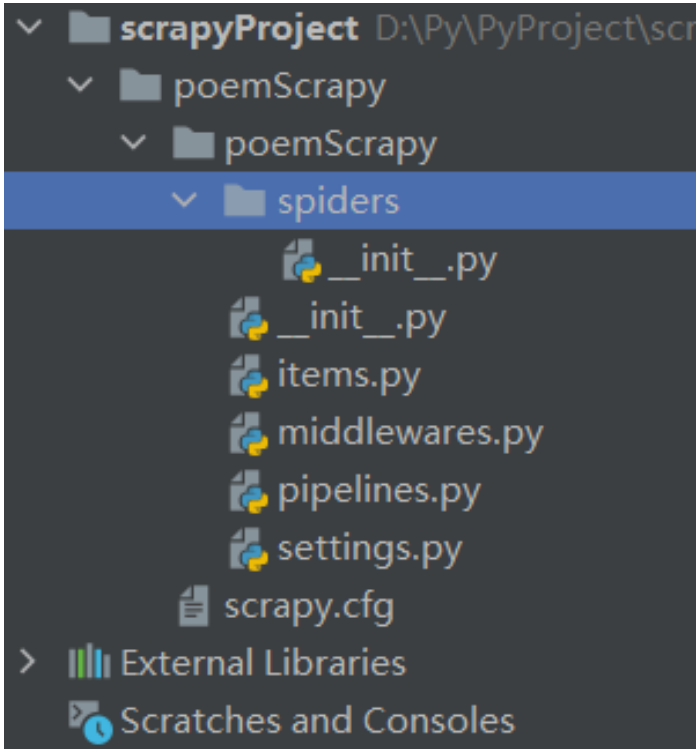

图3-9 Scrapy爬虫程序目录结构

3.7.3 Scrapy爬虫实例

在Scrapy爬虫程序目录结构中，各个目录和文件的作用如下：

- Spiders目录：该目录下包含爬虫文件，需编码实现爬虫过程；
- __init__.py：为Python模块初始化目录，可以什么都不写，但是必须要有；
- items.py：模型文件，存放了需要爬取的字段；
- middlewares.py：中间件（爬虫中间件、下载中间件），本案例中不用此文件；
- pipelines.py：管道文件，用于配置数据持久化，例如写入数据库；
- settings.py：爬虫配置文件；

scrapy.cfg：项目基础设置文件，设置爬虫启用功能等。在本案例中不用此文件。

3.7.3 Scrapy爬虫实例

2. 编写代码文件items.py

在items.py中定义字段用于保存数据，items.py的具体代码内容如下：

```
import scrapy

class PoemscrapyItem(scrapy.Item):
    # 名句
    sentence = scrapy.Field()
    # 出处
    source = scrapy.Field()
    # 全文链接
    url = scrapy.Field()
    # 名句详细信息
    content = scrapy.Field()
```

3.7.3 Scrapy爬虫实例

3.编写爬虫文件

在Terminal窗口输入命令“cd poemScrapy”，进入对应的爬虫工程中，再输入命令“scrapy genspider poemSpider gushiwen.cn”，这时，在spiders目录下会出现一个新的Python文件poemSpider.py，该文件就是我们要编写爬虫程序的位置。下面是poemSpider.py的具体代码：

3.7.3 Scrapy爬虫实例

```
import scrapy
from scrapy import Request
from ..items import PoemscrapyItem

class PoemspiderSpider(scrapy.Spider):
    name = 'poemSpider'   # 用于区别不同的爬虫
    allowed_domains = ['gushiwen.cn'] # 允许访问的域
    start_urls = ['http://so.gushiwen.cn/mingjus/'] # 爬取的地址

    def parse(self, response):
        # 先获每句名句的div
        for box in response.xpath('//*[@id="html"]/body/div[2]/div[1]/div[2]/div'):
            # 获取每句名句的链接
            url = 'https://so.gushiwen.cn' + box.xpath('.//@href').get()
            # 获取每句名句内容
            sentence = box.xpath('.//a[1]/text()') .get()
            # 获取每句名句出处
            source = box.xpath('.//a[2]/text()') .get()
            # 实例化容器
            item = PoemscrapyItem()
            # # 将收集到的信息封装起来
            item['url'] = url
            item['sentence'] = sentence
            item['source'] = source
            # 处理子页
            yield scrapy.Request(url=url, meta={'item': item}, callback=self.parse_detail)
        # 翻页
        next = response.xpath('//a[@class="amore"]/@href'). get()
        if next is not None:
            next_url = 'https://so.gushiwen.cn' + next
            # 处理下一页内容
            yield Request(next_url)
```

3.7.3 Scrapy爬虫实例

```
    def parse_detail(self, response):
        # 获取名句的详细信息
        item = response.meta['item']
        content_list =
response.xpath('//div[@class="contson"]//text()').getall()
        content = "".join(content_list).strip().replace('\n', '').replace('\u3000',
'')
        item['content'] = content
        yield item
```

3.7.3 Scrapy爬虫实例

在上面的代码中，response.xpath()返回的是scrapy.selector.unified.SelectorList对象，比如response.xpath('//div[@class="contson"]//text()')返回的部分结果如下：

[<Selector xpath='//div[@class="contson"]//text()' data='\n日日望乡国，空歌白苎词。'>, <Selector xpath='//div[@class="contson"]//text()' data='长因送人处，忆得别家时。'>, <Selector xpath='//div[@class="contson"]//text()' data='失意还独语，多愁只自知。'>, <Selector xpath='//div[@class="contson"]//text()' data='客亭门外柳，折尽向南枝。\n'>]

3.7.3 Scrapy爬虫实例

这时，response.xpath('//div[@class="contson"]//text()').get()返回的结果如下：

#注意，这里会输出一个空行

'日日望乡国，空歌白苎词。'

response.xpath('//div[@class="contson"]//text()').getall()返回的结果如下：

['\n日日望乡国，空歌白苎词。', '长因送人处，忆得别家时。', '失意还独语，多愁只自知。', '客亭门外柳，折尽向南枝。\n']

3.7.3 Scrapy爬虫实例

4.编写代码文件**pipelines.py**

当我们成功获取需要的信息后，要对信息进行存储。在Scrapy爬虫框架中，当item被爬虫收集完后，将会被传递到pipelines。现在要将爬取到的数据保存到文本文件中，可以使用的pipelines.py代码：

```
import json

class PoemscrapyPipeline:
    def __init__(self):
        # 打开文件
        self.file = open('data.txt', 'w', encoding='utf-8')

    def process_item(self, item, spider):
        # 读取item中的数据
        line = json.dumps(dict(item), ensure_ascii=False) + '\n'
        # 写入文件
        self.file.write(line)
        return item
```

3.7.3 Scrapy爬虫实例

5.编写代码文件settings.py

settings.py的具体代码如下：

```
BOT_NAME = 'poemScrapy'

SPIDER_MODULES = ['poemScrapy.spiders']
NEWSPIDER_MODULE = 'poemScrapy.spiders'

USER_AGENT = 'Mozilla/5.0 (Windows NT 10.0; WOW64) AppleWebKit/537.36
(KHTML, like Gecko) Chrome/90.0.4421.5 Safari/537.36'

# Obey robots.txt rules
ROBOTSTXT_OBEY = False

# 设置日志打印的等级
LOG_LEVEL = 'WARNING'

ITEM_PIPELINES = {
   'poemScrapy.pipelines.PoemscrapyPipeline': 1,
}
```

3.7.3 Scrapy爬虫实例

其中，更改USER-AGENT和ROBOTSTXT_OBEY是为了避免访问被拦截或出错；设置LOG_LEVEL是为了避免在爬取过程中显示过多的日志信息；设置ITEM_PIPELINES是因为本案例使用到pipeline，需要先注册pipeline，右侧的数字‘1’为该pipeline的优先级，范围1-1000，数值越小越优先执行。读者也可以根据实际需求，适当更改settings.py中的内容。

3.7.3 Scrapy爬虫实例

6.运行程序

有两种执行Scrapy爬虫的方法，第一种是在Terminal窗口中输入命令“scrapy crawl poemSpider”，然后回车运行，等待几秒钟后即可完成数据的爬取。第二种是在poemScrapy目录下新建Python文件run.py（run.py应与scrapy.cfg文件在同一层目录下），并输入下面代码：

```
from scrapy import cmdline
cmdline.execute("scrapy crawl poemSpider".split())
```

在run.py代码区域点击鼠标右键，在弹出的菜单里选择“Run”运行代码，就可以执行Scrapy爬虫程序。执行成功以后，就可以看到生成的数据文件data.txt，其内容类似如下：

```
{"url":
"https://so.gushiwen.cn/mingju/juv_2f9cf2c444f2.aspx",
"sentence": "人道恶盈而好谦。", "source": "《易传·彖传上·谦》",
"content":
```

3.7.3 Scrapy爬虫实例

7．把数据保存到数据库中

为了把爬取到的数据保存到MySQL数据库中，需要首先安装PyMySQL模块。在PyCharm开发界面中点击“File->Settings...”，在打开的设置界面中（如图3-10所示），先点击“Project scrapyProject”，再点击“Python Interpreter”，会弹出如图3-11所示的设置界面，点击界面底部的“+”。

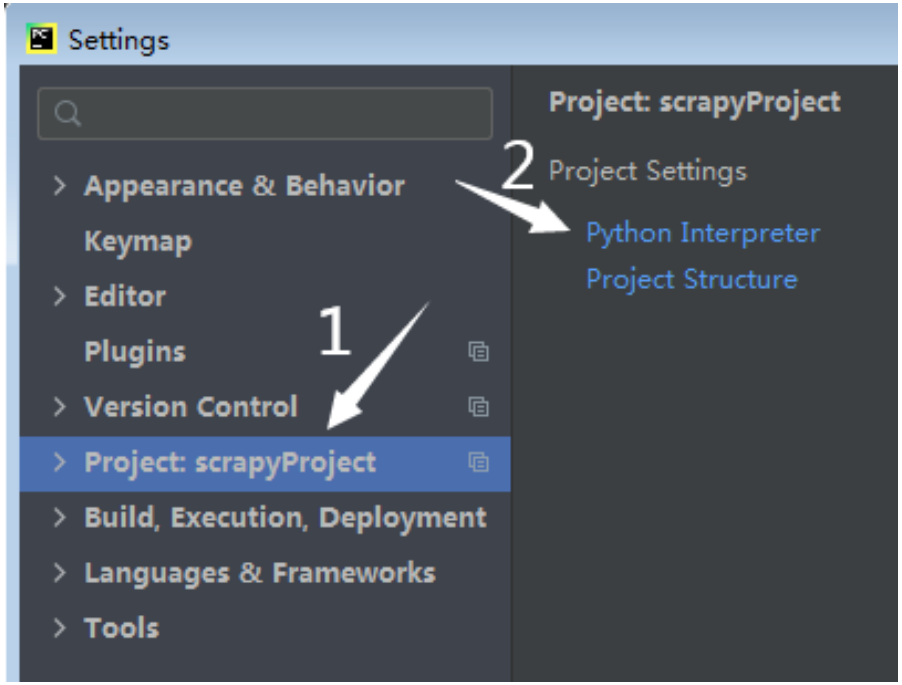

图3-10 设置界面

3.7.3 Scrapy爬虫实例

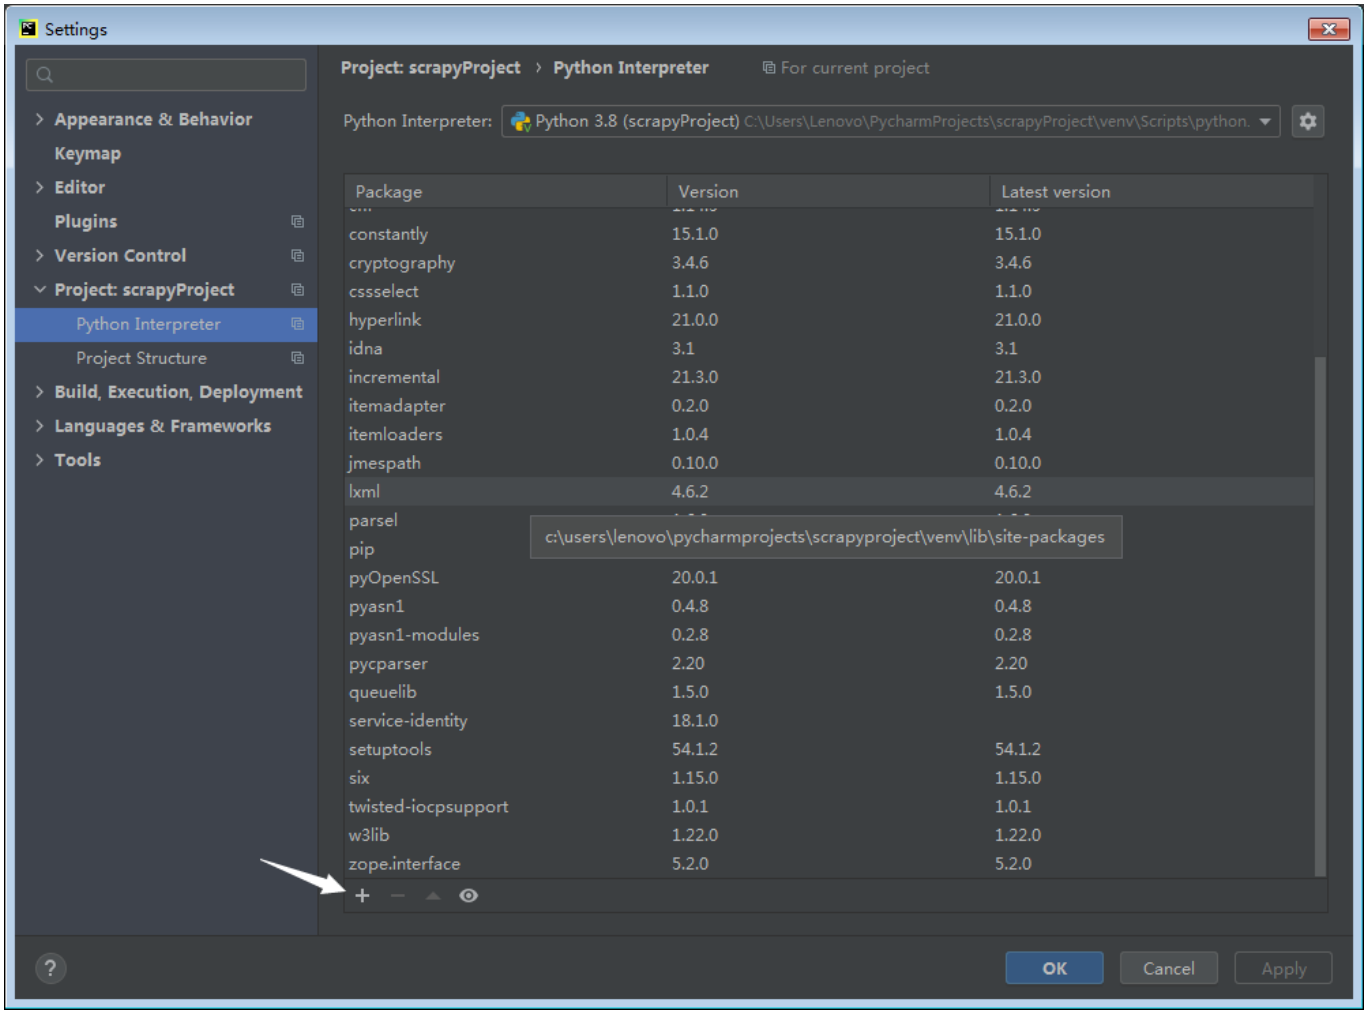

图3-11 在设置界面中点击“+”

3.7.3 Scrapy爬虫实例

在弹出的模块安装界面中（如图3-12所示），先在搜索框中输入“pymysql”，然后，在搜索到的结果中点击“PyMySQL”条目，最后，点击界面底部的“Install Package”，开始安装模块，如果安装成功，会出现如图3-13所示的信息。

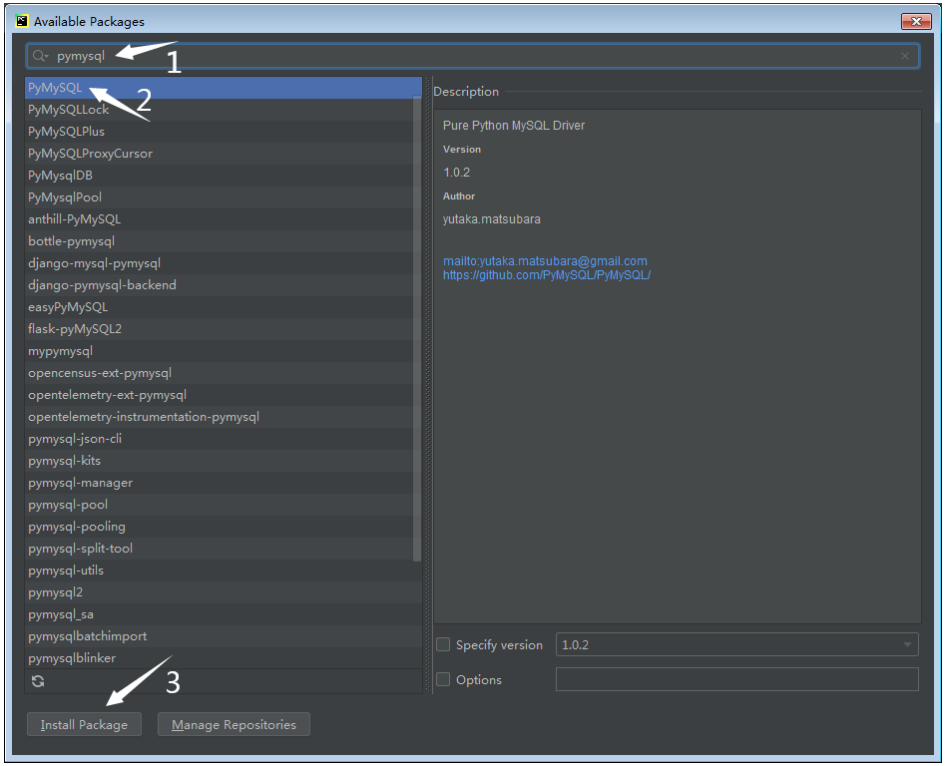

图3-12 模块安装界面

3.7.3 Scrapy爬虫实例

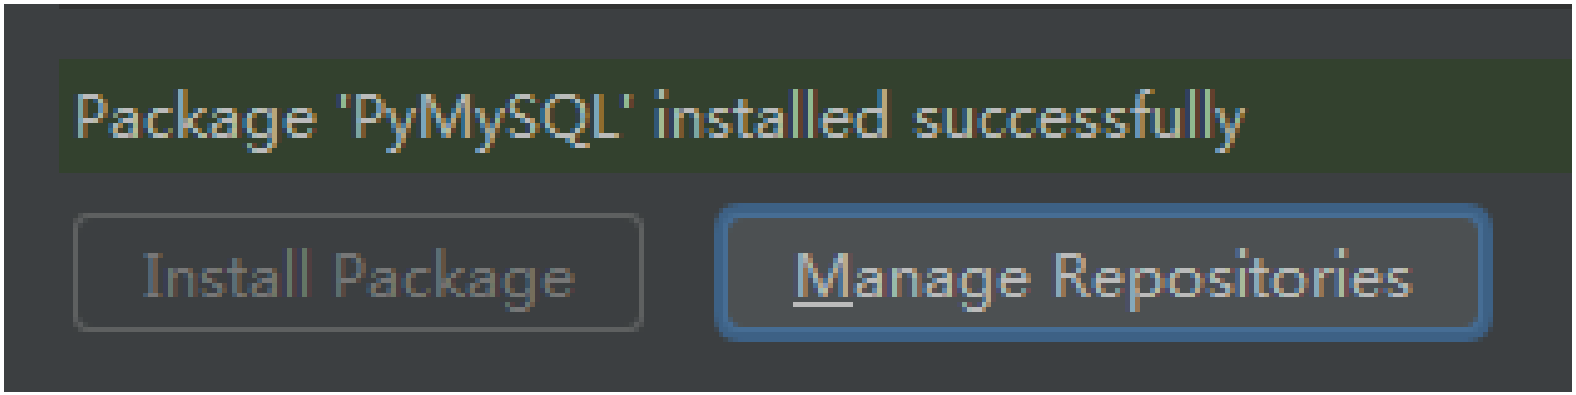

图3-13 模块安装成功

3.7.3 Scrapy爬虫实例

在Windows系统中启动MySQL服务进程，然后，打开MySQL命令行客户端，执行如下SQL语句创建一个名称为“poem”的数据库：

CREATE DATABASE poem;

然后，在poem数据库中创建一个名称为“beautifulsentence”的表，具体SQL语句如下：

```
DROP TABLE IF EXISTS `beautifulsentence`;
CREATE TABLE `beautifulsentence` (
  `source` varchar(255) NOT NULL,
  `sentence` varchar(255) NOT NULL,
  `content` text NOT NULL,
  `url` varchar(255) NOT NULL
) ENGINE=InnoDB DEFAULT CHARSET=utf8;
```

3.7.3 Scrapy爬虫实例

修改pipelines.py，编写完成以后的pipelines.py代码如下：

```
from itemadapter import ItemAdapter
import json
import pymysql

class PoemscrapyPipeline:
    def __init__(self):
        # 连接MySQL数据库
        self.connect = pymysql.connect(
            host='localhost',
            port=3306,
            user='root',
            passwd='123456',  #设置成用户自己的数据库密码
            db='poem',
            charset='utf8'
        )
        self.cursor = self.connect.cursor()

    def process_item(self, item, spider):
        # 写入数据库
        self.cursor.execute('INSERT INTO beautifulsentence(source,sentence,content,url)
VALUES ("{}","{}","{}","{}")'.format(item['source'], item['sentence'], item['content'],
item['url']))
        self.connect.commit()
        return item
def close_spider(self, spider):
    # 关闭数据库连接
        self.cursor.close()
        self.connect.close()
```

3.7.3 Scrapy爬虫实例

执行Scrapy爬虫程序，执行结束以后，如果执行成功，可以到MySQL数据库中使用如下命令查看数据：

```
USE poem;
SELECT * FROM beautifulsentence;
```

3.8 本章小结

网络爬虫系统的功能是下载网页数据，为搜索引擎系统或需要网络数据的企业提供数据来源。本章内容介绍了网络爬虫程序的编写方法，主要包括如何请求网页以及如何解析网页。在网页请求环节，需要注意的是，一些网站设置了反爬机制，会导致我们爬取网页失败。在网页解析环节，我们可以灵活运用BeautifulSoup提供的各种方法获取我们需要的数据。同时，为了减少程序开发工作量，可以选择包括Scrapy在内的一些网络爬虫开发框架编写网络网络爬虫程序。

附录A：主讲教师林子雨简介

主讲教师：林子雨

单位：厦门大学计算机科学与技术系
E-mail: ziyulin@xmu.edu.cn
个人网页：http://dblab.xmu.edu.cn/linziyu
数据库实验室网站：http://dblab.xmu.edu.cn

扫一扫访问个人主页

林子雨，男，1978年出生，博士（毕业于北京大学），全国高校知名大数据教师，现为厦门大学计算机科学系副教授，厦门大学信息学院实验教学中心主任，曾任厦门大学信息科学与技术学院院长助理、晋江市发展和改革局副局长。中国计算机学会数据库专业委员会委员，中国计算机学会信息系统专业委员会委员。国内高校首个“数字教师”提出者和建设者，厦门大学数据库实验室负责人，厦门大学云计算与大数据研究中心主要建设者和骨干成员，2013年度、2017年度和2020年度厦门大学教学类奖教金获得者，荣获2019年福建省精品在线开放课程、2018年厦门大学高等教育成果特等奖、2018年福建省高等教育教学成果二等奖、2018年国家精品在线开放课程。主要研究方向为数据库、数据仓库、数据挖掘、大数据、云计算和物联网，并以第一作者身份在《软件学报》《计算机学报》和《计算机研究与发展》等国家重点期刊以及国际学术会议上发表多篇学术论文。作为项目负责人主持的科研项目包括1项国家自然科学青年基金项目(No.61303004)、1项福建省自然科学青年基金项目(No.2013J05099)和1项中央高校基本科研业务费项目(No.2011121049)，主持的教改课题包括1项2016年福建省教改课题和1项2016年教育部产学协作育人项目，同时，作为课题负责人完成了国家发改委城市信息化重大课题、国家物联网重大应用示范工程区域试点泉州市工作方案、2015泉州市互联网经济调研等课题。中国高校首个“数字教师”提出者和建设者，2009年至今，“数字教师”大平台累计向网络免费发布超过1000万字高价值的研究和教学资料，累计网络访问量超过1000万次。打造了中国高校大数据教学知名品牌，编著出版了中国高校第一本系统介绍大数据知识的专业教材《大数据技术原理与应用》，并成为京东、当当网等网店畅销书籍；建设了国内高校首个大数据课程公共服务平台，为教师教学和学生学习大数据课程提供全方位、一站式服务，年访问量超过400万次，累计访问量超过1500万次。

附录B：大数据学习路线图

大数据学习路线图访问地址：http://dblab.xmu.edu.cn/post/10164/

附录C：林子雨大数据系列教材

了解全部教材信息：http://dblab.xmu.edu.cn/post/bigdatabook/

附录D：《大数据导论（通识课版）》教材

开设全校公共选修课的优质教材

本课程旨在实现以下几个培养目标：

- 引导学生步入大数据时代，积极投身大数据的变革浪潮之中
- 了解大数据概念，培养大数据思维，养成数据安全意识
- 认识大数据伦理，努力使自己的行为符合大数据伦理规范要求
- 熟悉大数据应用，探寻大数据与自己专业的应用结合点
- 激发学生基于大数据的创新创业热情

高等教育出版社 ISBN:978-7-04-053577-8 定价：32元 版次：2020年2月第1版
教材官网：http://dblab.xmu.edu.cn/post/bigdataintroduction/

附录E：《大数据导论》教材

- 林子雨 编著《大数据导论》
- 人民邮电出版社，2020年9月第1版
- ISBN:978-7-115-54446-9 定价：49.80元

教材官网：http://dblab.xmu.edu.cn/post/bigdata-introduction/

开设大数据专业导论课的优质教材

扫一扫访问教材官网

附录F：《大数据技术原理与应用（第3版）》教材

《大数据技术原理与应用——概念、存储、处理、分析与应用（第3版）》，由厦门大学计算机科学系林子雨博士编著，是国内高校第一本系统介绍大数据知识的专业教材。人民邮电出版社　ISBN:978-7-115-54405-6　定价：59.80元

全书共有17章，系统地论述了大数据的基本概念、大数据处理架构Hadoop、分布式文件系统HDFS、分布式数据 库HBase、NoSQL数据库、云数据库、分布式并行编程模型MapReduce、Spark、流计算、Flink、图计算、数据可视化以及大数据在互联网、生物医学和物流等各个领域的应用。在Hadoop、HDFS、HBase、MapReduce、Spark和Flink等重要章节，安排了入门级的实践操作，让读者更好地学习和掌握大数据关键技术。

本书可以作为高等院校计算机专业、信息管理等相关专业的大数据课程教材，也可供相关技术人员参考、学习、培训之用。

欢迎访问《大数据技术原理与应用——概念、存储、处理、分析与应用》教材官方网站：
http://dblab.xmu.edu.cn/post/bigdata3

扫一扫访问教材官网

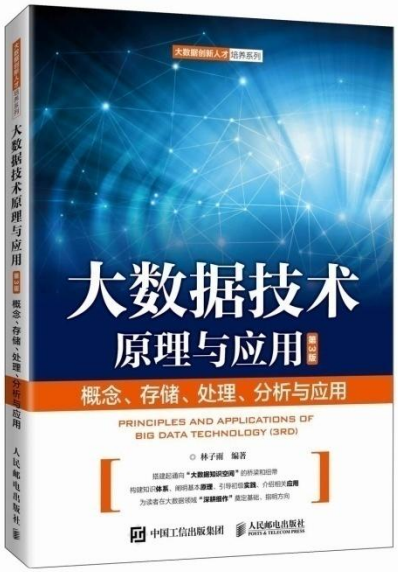

附录G：《大数据基础编程、实验和案例教程（第2版）》

本书是与《大数据技术原理与应用（第3版）》教材配套的唯一指定实验指导书

大数据教材

1+1黄金组合

厦门大学林子雨编著

配套实验指导书

- 步步引导，循序渐进，详尽的安装指南为顺利搭建大数据实验环境铺平道路
- 深入浅出，去粗取精，丰富的代码实例帮助快速掌握大数据基础编程方法
- 精心设计，巧妙融合，八套大数据实验题目促进理论与编程知识的消化和吸收
- 结合理论，联系实际，大数据课程综合实验案例精彩呈现大数据分析全流程

林子雨编著《大数据基础编程、实验和案例教程（第2版）》
清华大学出版社 ISBN:978-7-302-55977-1 定价：69元 2020年10月第2版

附录H：《Spark编程基础（Scala版）》

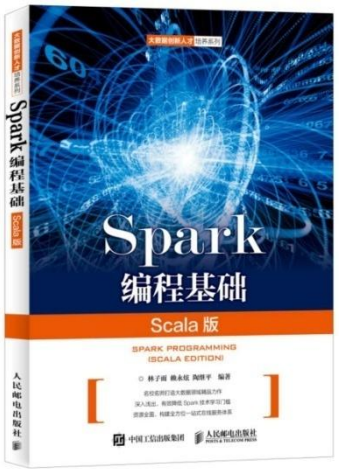

《Spark编程基础（Scala版）》

厦门大学 林子雨，赖永炫，陶继平 编著

披荆斩棘，在大数据丛林中开辟学习捷径
填沟削坎，为快速学习Spark技术铺平道路
深入浅出，有效降低Spark技术学习门槛
资源全面，构建全方位一站式在线服务体系

人民邮电出版社出版发行，ISBN:978-7-115-48816-9

教材官网：http://dblab.xmu.edu.cn/post/spark/

本书以Scala作为开发Spark应用程序的编程语言，系统介绍了Spark编程的基础知识。全书共8章，内容包括大数据技术概述、Scala语言基础、Spark的设计与运行原理、Spark环境搭建和使用方法、RDD编程、Spark SQL、Spark Streaming、Spark MLlib等。本书每个章节都安排了入门级的编程实践操作，以便读者更好地学习和掌握Spark编程方法。本书官网免费提供了全套的在线教学资源，包括讲义PPT、习题、源代码、软件、数据集、授课视频、上机实验指南等。

附录I：《Spark编程基础（Python版）》

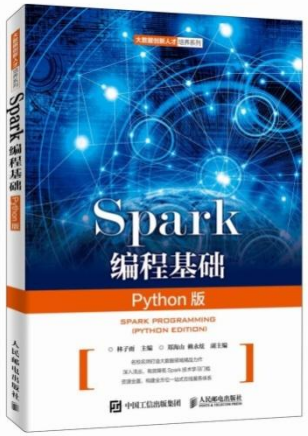

《Spark编程基础（Python版）》

厦门大学 林子雨，郑海山，赖永炫 编著

披荆斩棘，在大数据丛林中开辟学习捷径
填沟削坎，为快速学习Spark技术铺平道路
深入浅出，有效降低Spark技术学习门槛
资源全面，构建全方位一站式在线服务体系

人民邮电出版社出版发行，ISBN:978-7-115-52439-3

教材官网： http://dblab.xmu.edu.cn/post/spark-python/

本书以Python作为开发Spark应用程序的编程语言，系统介绍了Spark编程的基础知识。全书共8章，内容包括大数据技术概述、Spark的设计与运行原理、Spark环境搭建和使用方法、RDD编程、Spark SQL、Spark Streaming、Structured Streaming、Spark MLlib等。本书每个章节都安排了入门级的编程实践操作，以便读者更好地学习和掌握Spark编程方法。本书官网免费提供了全套的在线教学资源，包括讲义PPT、习题、源代码、软件、数据集、上机实验指南等。

附录J：高校大数据课程公共服务平台

高校大数据课程

公 共 服 务 平 台

http://dblab.xmu.edu.cn/post/bigdata-teaching-platform/

扫一扫访问平台主页

扫一扫观看3分钟FLASH动画宣传片

附录K：高校大数据实训课程系列案例教材

为了更好满足高校开设大数据实训课程的教材需求，厦门大学数据库实验室林子雨老师团队联合企业共同开发了《高校大数据实训课程系列案例》，目前已经完成开发的系列案例包括：

《电影推荐系统》（已经于2019年5月出版）
《电信用户行为分析》（已经于2019年5月出版）
《实时日志流处理分析》
《微博用户情感分析》
《互联网广告预测分析》
《网站日志处理分析》

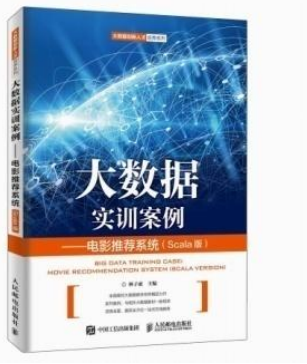

系列案例教材将于2019年陆续出版发行，教材相关信息，敬请关注网页后续更新！
http://dblab.xmu.edu.cn/post/shixunkecheng/

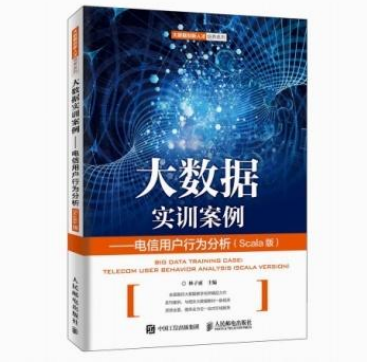

扫一扫访问大数据实训课程系列案例教材主页


Thank You!