在前面的示例中我们已经了解了 Item Pipeline 项目管道的基本概念，本节课我们就深入详细讲解它的用法。

首先我们看看 Item Pipeline 在 Scrapy 中的架构，如图所示。

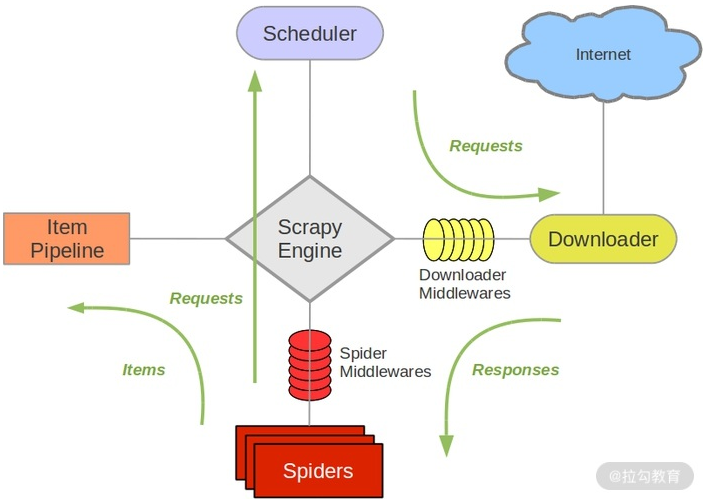

图中的最左侧即为 Item Pipeline，它的调用发生在 Spider 产生 Item 之后。当 Spider 解析完 Response 之后，Item 就会传递到 Item Pipeline，被定义的 Item Pipeline 组件会顺次调用，完成一连串的处理过程，比如数据清洗、存储等。

它的主要功能有：

- 清洗 HTML 数据；
- 验证爬取数据，检查爬取字段；
- 查重并丢弃重复内容；
- 将爬取结果储存到数据库。

1. 核心方法

我们可以自定义 Item Pipeline，只需要实现指定的方法就可以，其中必须要实现的一个方法是：

- process_item(item, spider)

另外还有几个比较实用的方法，它们分别是：

- open_spider(spider)
- close_spider(spider)
- from_crawler(cls, crawler)

下面我们对这几个方法的用法做下详细的介绍：

process_item(item, spider)

process_item() 是必须要实现的方法，被定义的 Item Pipeline 会默认调用这个方法对 Item 进行处理。比如，我们可以进行数据处理或者将数据写入数据库等操作。它必须返回 Item 类型的值或者抛出一个 DropItem 异常。

process_item() 方法的参数有如下两个：

- item，是 Item 对象，即被处理的 Item；
- spider，是 Spider 对象，即生成该 Item 的 Spider。

下面对该方法的返回类型归纳如下：

- 如果返回的是 Item 对象，那么此 Item 会被低优先级的 Item Pipeline 的 process_item() 方法进行处理，直到所有的方法被调用完毕。
- 如果抛出的是 DropItem 异常，那么此 Item 就会被丢弃，不再进行处理。

open_spider(self, spider)

open_spider() 方法是在 Spider 开启的时候被自动调用的，在这里我们可以做一些初始化操作，如开启数据库连接等。其中参数 spider 就是被开启的 Spider 对象。

close_spider(spider)

close_spider() 方法是在 Spider 关闭的时候自动调用的，在这里我们可以做一些收尾工作，如关闭数据库连接等，其中参数 spider 就是被关闭的 Spider 对象。

from_crawler(cls, crawler)

from_crawler() 方法是一个类方法，用 @classmethod 标识，是一种依赖注入的方式。它的参数是 crawler，通过 crawler 对象，我们可以拿到 Scrapy 的所有核心组件，如全局配置的每个信息，然后创建一个 Pipeline 实例。参数 cls 就是 Class，最后返回一个 Class 实例。

下面我们用一个实例来加深对 Item Pipeline 用法的理解。

2. 本节目标

我们以爬取 360 摄影美图为例，来分别实现 MongoDB 存储、MySQL 存储、Image 图片存储的三个 Pipeline。

3. 准备工作

请确保已经安装好 MongoDB 和 MySQL 数据库，安装好 Python 的 PyMongo、PyMySQL、Scrapy 框架，另外需要安装 pillow 图像处理库，如果没有安装可以参考前文的安装说明。

4. 抓取分析

我们这次爬取的目标网站为：https://image.so.com。打开此页面，切换到摄影页面，网页中呈现了许许多多的摄影美图。我们打开浏览器开发者工具，过滤器切换到 XHR 选项，然后下拉页面，可以看到下面就会

呈现许多 Ajax 请求，如图所示。

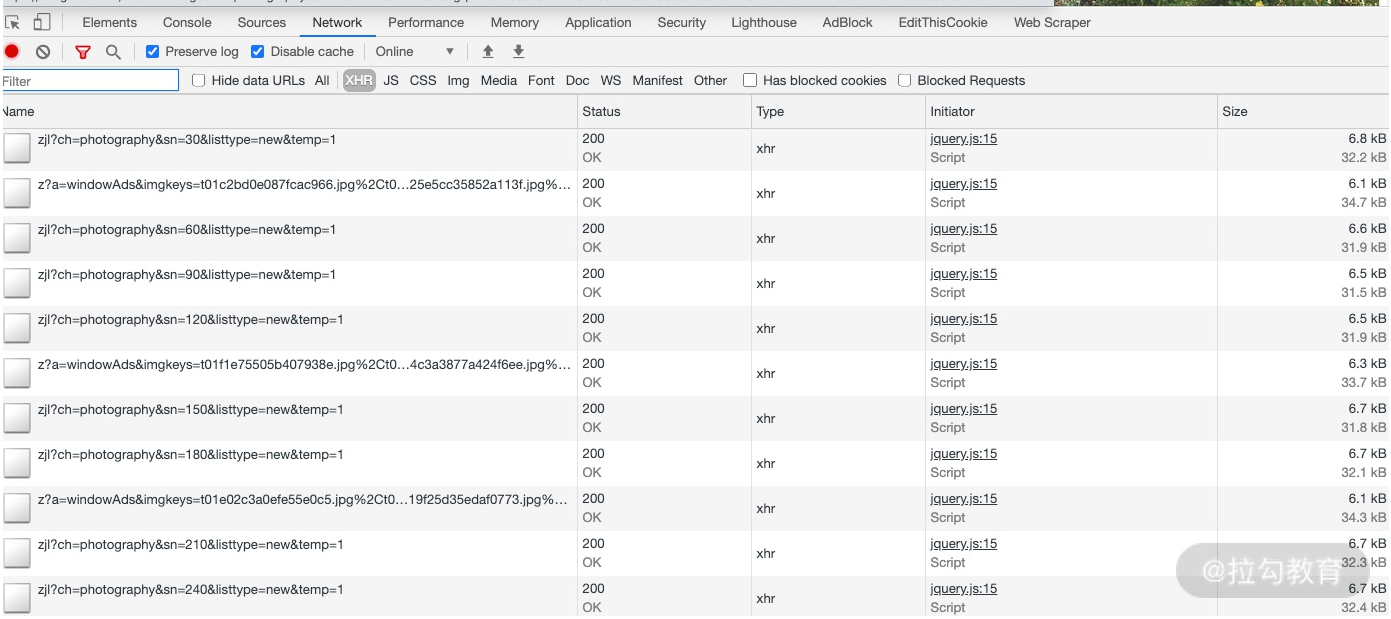

我们查看一个请求的详情，观察返回的数据结构，如图所示。

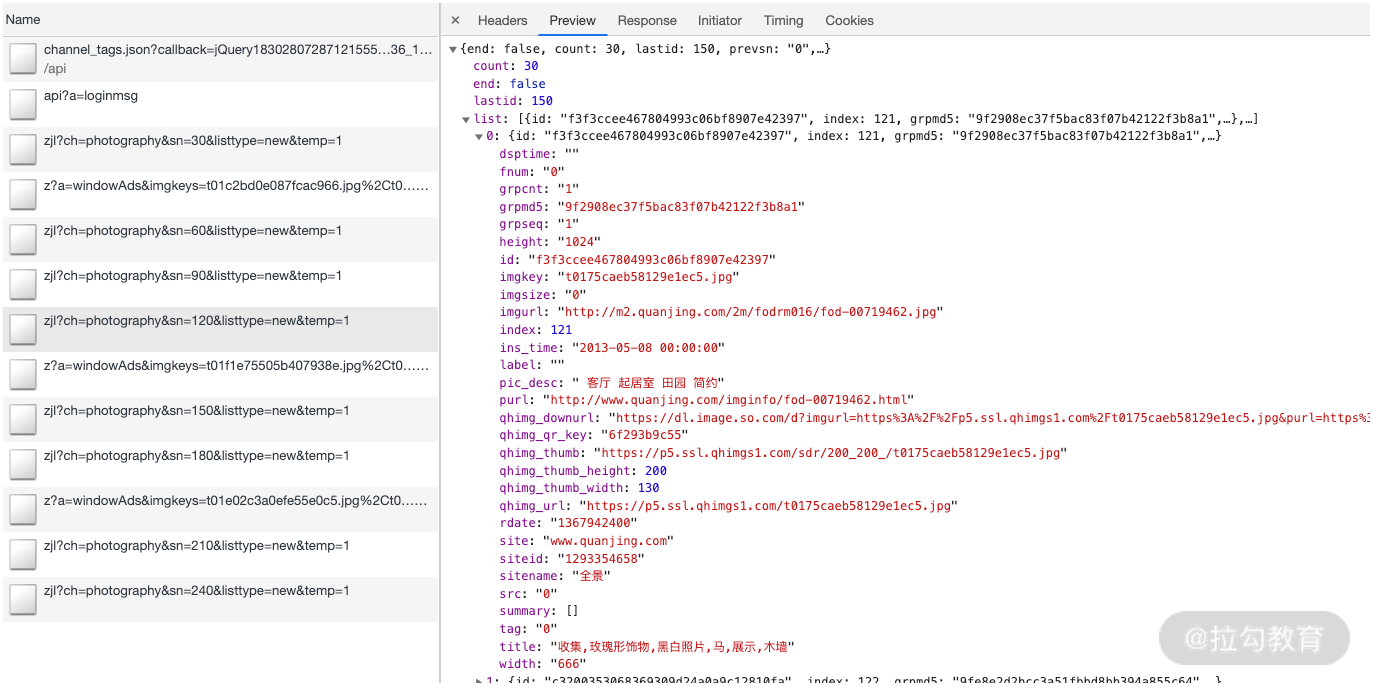

返回格式是 JSON。其中 list 字段就是一张张图片的详情信息，包含了 30 张图片的 ID、名称、链接、缩略图等信息。另外观察 Ajax 请求的参数信息，有一个参数 sn 一直在变化，这个参数很明显就是偏移量。当 sn 为 30 时，返回的是前 30 张图片，sn 为 60 时，返回的就是第 31~60 张图片。另外，ch 参数是摄影类别，listtype 是排序方式，temp 参数可以忽略。

所以我们抓取时只需要改变 sn 的数值就好了。下面我们用 Scrapy 来实现图片的抓取，将图片的信息保存到 MongoDB、MySQL，同时将图片存储到本地。

5. 新建项目

首先新建一个项目，命令如下：

```
scrapy startproject images360
```

接下来新建一个 Spider，命令如下：

```
scrapy genspider images images.so.com
```

这样我们就成功创建了一个 Spider。

6. 构造请求

接下来定义爬取的页数。比如爬取 50 页、每页 30 张，也就是 1500 张图片，我们可以先在 settings.py 里面定义一个变量 MAX_PAGE，添加如下定义：

```
MAX_PAGE = 50
```

定义 start_requests() 方法，用来生成 50 次请求，如下所示：

```
def start_requests(self):
    data = {'ch': 'photography', 'listtype': 'new'}
    base_url = 'https://image.so.com/zjl?'
    for page in range(1, self.settings.get('MAX_PAGE') + 1):
        data['sn'] = page * 30
        params = urlencode(data)
        url = base_url + params
        yield Request(url, self.parse)
```

在这里我们首先定义了初始的两个参数，sn 参数是遍历循环生成的。然后利用 urlencode 方法将字典转化为 URL 的 GET 参数，构造出完整的 URL，构造并生成 Request。

还需要引入 scrapy.Request 和 urllib.parse 模块，如下所示：

```
from scrapy import Spider, Request
from urllib.parse import urlencode
```

再修改 settings.py 中的 ROBOTSTXT_OBEY 变量，将其设置为 False，否则无法抓取，如下所示：

```
ROBOTSTXT_OBEY = False
```

运行爬虫，即可以看到链接都请求成功，执行命令如下所示：

```
scrapy crawl images
```

运行示例结果如图所示。

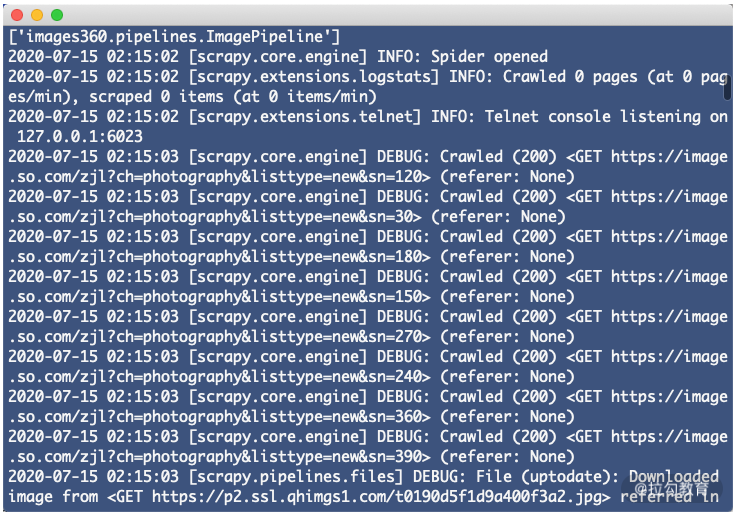

所有请求的状态码都是 200，这就证明图片信息爬取成功了。

7. 提取信息

首先定义一个叫作 ImageItem 的 Item，如下所示：

```
from scrapy import Item, Field
class ImageItem(Item):
    collection = table = 'images'
    id = Field()
    url = Field()
    title = Field()
    thumb = Field()
```

在这里我们定义了 4 个字段，包括图片的 ID、链接、标题、缩略图。另外还有两个属性 collection 和 table，都定义为 images 字符串，分别代表 MongoDB 存储的 Collection 名称和 MySQL 存储的表名称。
接下来我们提取 Spider 里有关信息，将 parse 方法改写为如下所示：

```
def parse(self, response):
    result = json.loads(response.text)
    for image in result.get('list'):
        item = ImageItem()
        item['id'] = image.get('id')
        item['url'] = image.get('qhimg_url')
        item['title'] = image.get('title')
        item['thumb'] = image.get('qhimg_thumb')
        yield item
```

首先解析 JSON，遍历其 list 字段，取出一个个图片信息，然后再对 ImageItem 进行赋值，生成 Item 对象。
这样我们就完成了信息的提取。

8. 存储信息

接下来我们需要将图片的信息保存到 MongoDB、MySQL 中，同时将图片保存到本地。

MongoDB

首先确保 MongoDB 已经正常安装并且能够正常运行。

我们用一个 MongoPipeline 将信息保存到 MongoDB 中，在 pipelines.py 里添加如下类的实现：

```
import pymongo
class MongoPipeline(object):
    def __init__(self, mongo_uri, mongo_db):
        self.mongo_uri = mongo_uri
```

```
        self.mongo_db = mongo_db

    @classmethod
    def from_crawler(cls, crawler):
        return cls(mongo_uri=crawler.settings.get('MONGO_URI'),
            mongo_db=crawler.settings.get('MONGO_DB')
        )
    def open_spider(self, spider):
        self.client = pymongo.MongoClient(self.mongo_uri)
        self.db = self.client[self.mongo_db]
    def process_item(self, item, spider):
        self.db[item.collection].insert(dict(item))
        return item
    def close_spider(self, spider):
        self.client.close()
```

这里需要用到两个变量，MONGO_URI 和 MONGO_DB，即存储到 MongoDB 的链接地址和数据库名称。我们在 settings.py 里添加这两个变量，如下所示：

```
MONGO_URI = 'localhost'
MONGO_DB = 'images360'
```

这样一个保存到 MongoDB 的 Pipeline 的就创建好了。这里最主要的方法是 process_item()，直接调用 Collection 对象的 insert 方法即可完成数据的插入，最后返回 Item 对象。

MySQL

首先需要确保 MySQL 已经正确安装并且正常运行。

新建一个数据库，名字还是 images360，SQL 语句如下所示：

```
CREATE DATABASE images360 DEFAULT CHARACTER SET utf8 COLLATE utf8_general_ci
```

新建一个数据表，包含 id、url、title、thumb 四个字段，SQL 语句如下所示：

```
CREATE TABLE images (id VARCHAR(255) NULL PRIMARY KEY, url VARCHAR(255) NULL , title VARCHAR(255) NULL , thumb VARCHAR(255) NULL)
```

执行完 SQL 语句之后，我们就成功创建好了数据表。接下来就可以往表里存储数据了。

接下来我们实现一个 MySQLPipeline，代码如下所示：

```
import pymysql
class MysqlPipeline():
    def __init__(self, host, database, user, password, port):
        self.host = host
        self.database = database
        self.user = user
        self.password = password
        self.port = port

    @classmethod
    def from_crawler(cls, crawler):
        return cls(host=crawler.settings.get('MYSQL_HOST'),
            database=crawler.settings.get('MYSQL_DATABASE'),
            user=crawler.settings.get('MYSQL_USER'),
            password=crawler.settings.get('MYSQL_PASSWORD'),
            port=crawler.settings.get('MYSQL_PORT'),
        )

    def open_spider(self, spider):
        self.db = pymysql.connect(self.host, self.user, self.password, self.database, charset='utf8', port=self.port)
        self.cursor = self.db.cursor()

    def close_spider(self, spider):
        self.db.close()

    def process_item(self, item, spider):
        data = dict(item)
        keys = ', '.join(data.keys())
        values = ', '.join(['% s'] * len(data))
        sql = 'insert into % s (% s) values (% s)' % (item.table, keys, values)
        self.cursor.execute(sql, tuple(data.values()))
        self.db.commit()
        return item
```

如前所述，这里用到的数据插入方法是一个动态构造 SQL 语句的方法。

这里还需要几个 MySQL 的配置，我们在 settings.py 里添加几个变量，如下所示：

```
MYSQL_HOST = 'localhost'
MYSQL_DATABASE = 'images360'
MYSQL_PORT = 3306
MYSQL_USER = 'root'
MYSQL_PASSWORD = '123456'
```

这里分别定义了 MySQL 的地址、数据库名称、端口、用户名、密码。这样，MySQL Pipeline 就完成了。

Image Pipeline

Scrapy 提供了专门处理下载的 Pipeline，包括文件下载和图片下载。下载文件和图片的原理与抓取页面的原理一样，因此下载过程支持异步和多线程，十分高效。下面我们来看看具体的实现过程。

官方文档地址为：https://doc.scrapy.org/en/latest/topics/media-pipeline.html。

首先定义存储文件的路径，需要定义一个 IMAGES_STORE 变量，在 settings.py 中添加如下代码：

```
IMAGES_STORE = './images'
```

在这里我们将路径定义为当前路径下的 images 子文件夹，即下载的图片都会保存到本项目的 images 文件夹中。

内置的 ImagesPipeline 会默认读取 Item 的 image_urls 字段，并认为该字段是一个列表形式，它会遍历 Item 的 image_urls 字段，然后取出每个 URL 进行图片下载。

但是现在生成的 Item 的图片链接字段并不是 image_urls 字段表示的，也不是列表形式，而是单个的 URL。所以为了实现下载，我们需要重新定义下载的部分逻辑，即需要自定义 ImagePipeline，继承内置的 ImagesPipeline，重写方法。

我们定义 ImagePipeline，如下所示：

```
from scrapy import Request
from scrapy.exceptions import DropItem
from scrapy.pipelines.images import ImagesPipeline
class ImagePipeline(ImagesPipeline):
    def file_path(self, request, response=None, info=None):
        url = request.url
        file_name = url.split('/')[-1]
        return file_name

    def item_completed(self, results, item, info):
        image_paths = [x['path'] for ok, x in results if ok]
        if not image_paths:
```

```
            raise DropItem('Image Downloaded Failed')
        return item

    def get_media_requests(self, item, info):
        yield Request(item['url'])
```

在这里我们实现了 ImagePipeline，继承 Scrapy 内置的 ImagesPipeline，重写了下面几个方法。

- get_media_requests()。它的第一个参数 item 是爬取生成的 Item 对象。我们将它的 url 字段取出来，然后直接生成 Request 对象。此 Request 加入调度队列，等待被调度，执行下载。
- file_path()。它的第一个参数 request 就是当前下载对应的 Request 对象。这个方法用来返回保存的文件名，直接将图片链接的最后一部分当作文件名即可。它利用 split() 函数分割链接并提取最后一部分，返回结果。这样此图片下载之后保存的名称就是该函数返回的文件名。
- item_completed()，它是当单个 Item 完成下载时的处理方法。因为并不是每张图片都会下载成功，所以我们需要分析下载结果并剔除下载失败的图片。如果某张图片下载失败，那么我们就不需保存此 Item 到数据库。该方法的第一个参数 results 就是该 Item 对应的下载结果，它是一个列表形式，列表每一个元素是一个元组，其中包含了下载成功或失败的信息。这里我们遍历下载结果找出所有成功的下载列表。如果列表为空，那么该 Item 对应的图片下载失败，随即抛出异常 DropItem，该 Item 忽略。否则返回该 Item，说明此 Item 有效。

现在为止，三个 Item Pipeline 的定义就完成了。最后只需要启用就可以了，修改 settings.py，设置 ITEM_PIPELINES，如下所示：

```
ITEM_PIPELINES = {
    'images360.pipelines.ImagePipeline': 300,
    'images360.pipelines.MongoPipeline': 301,
    'images360.pipelines.MysqlPipeline': 302,
}
```

这里注意调用的顺序。我们需要优先调用 ImagePipeline 对 Item 做下载后的筛选，下载失败的 Item 就直接忽略，它们就不会保存到 MongoDB 和 MySQL 里。随后再调用其他两个存储的 Pipeline，这样就能确保保存入数据库的图片都是下载成功的。
接下来运行程序，执行爬取，如下所示：

```
scrapy crawl images
```

爬虫一边爬取一边下载，下载速度非常快，对应的输出日志如图所示。

查看本地 images 文件夹，发现图片都已经成功下载，如图所示。

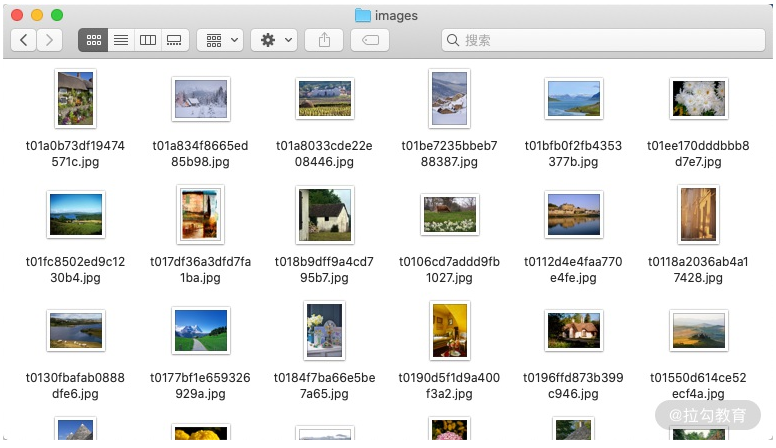

查看 MySQL，下载成功的图片信息也已成功保存，如图所示。

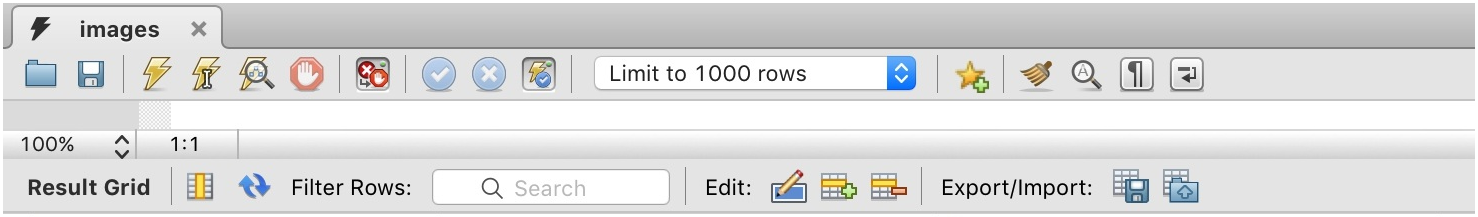

id	url	title	thu
001471af5d96282a19af0a34e99e4f12	https://p2.ssl.qhimgs1.com/t0158124abfc0291fae.jpg	条纹,土地,家园,萨斯喀彻温,加拿大	http
001ff119dc4ea819da51d6aca12db2c0	https://p5.ssl.qhimgs1.com/t017bb7ddd135355f…	奢华,小,酒店,餐馆,法国乡村,物主,鲁伯隆,沃克吕…	http
0052744e20d265169fc72818b98bddf5	https://p4.ssl.qhimgs1.com/t01519a00469f02e3…	新斯科舍省,加拿大	http
00d458713384e7acf15e6014172802c9	https://ps.ssl.qhmsg.com/t019fb971b9f0c16747.jpg	在弗里希利亚纳西班牙街	http
011e76a87052917f59b194b607b8647d	https://p2.ssl.qhimgs1.com/t01982d20153c7c8a…	乡村,室内	http
012f11745a9e4603543ef6901a6dbb97	https://p3.ssl.qhimgs1.com/t014ed02c4de1293a…	太阳,甲板,红色,大,软长椅,沙发,鲜明,绿色,茂密,…	http
01437e99a5d208c2e6270c174c1e65b5	https://p4.ssl.qhimgs1.com/t01db7fbaea7382f0f4.jpg	房子,山,省立公园,里贾纳,萨斯喀彻温,加拿大	http
0190efe7cc6308a0aa783f706cbde9b2	https://p0.ssl.qhimgs1.com/t0195c7fbd9494f2800.jpg	半边莲花园椅	http
019b8d3a567d7ccd016c7e033ad2f4ac	https://p0.ssl.qhimgs1.com/t0174b1f5834596d1…	俯视,城镇,纽芬兰,加拿大	http
01c8619756e2e0b50075f50195232060	https://p2.ssl.qhimgs1.com/t012cbf9197f26edcfe.jpg	农舍,草地,岛屿,马格达伦群岛,魁北克,加拿大,北美	http
0207c0af7e1c88ad41649df2a0cc88ad	https://p5.ssl.qhimgs1.com/t0152541990b29102…	斯科派洛斯岛,城镇,斯波拉提群岛,岛屿,希腊群岛…	http
021a7dba37202c58091e4e9c2c9cd374	https://ps.ssl.qhmsg.com/t01de4bed22342c4855.jpg	蒙蒂基罗托斯卡纳	http
021d11618469779c7e07e959a5f4bff3	https://p1.ssl.qhimgs1.com/t0139480d9c1bff8b61.jpg	简单,实用,赤陶,创作,墙壁,卫生间	http
022581e3ce8026887756b32423b0c60f	https://p4.ssl.qhimgs1.com/t017a773033c0e744…	Wooden fence and derelict house, Bodie ghost town	http
0257d0074b397fb223c417b5e18312fa	https://p2.ssl.qhimgs1.com/t013cc32341b857ef…	特写,栏杆,老,木质,楼梯,住宅,原木,家,魁北克,加…	http
028f3f14bbac5b5906efa6f0a3ec1675	https://p5.ssl.qhimgs1.com/t0177a0dd89c0c1e5…	乡村,环境,卧室,华丽,手绘,四柱床,签名,风格	http
02fb0790f8fda2f91242232888a12a0d	https://p1.ssl.qhimgs1.com/t01998b3671af2d72…	老式厨房的场景	http
0300ec39f19036848c58bbbdf3f6e987	https://ps.ssl.qhmsg.com/t0146a6d1d9a8066786.jpg	传统的乡村厨房	http
031fd364aab65b8d96eb7a53820b2c20	https://ps.ssl.qhmsg.com/t012f91537a20df68f8.jpg	坎特伯雷,乡村,新罕布什尔,新英格兰,美国,北美	http
03aa6080e83a1a8be6cd18cbf4734a36	https://p1.ssl.qhimgs1.com/t01262da5bcf861bd…	静物,面包,奶酪,蛋,正面,农舍	http
040df5e33246cece56933c9f87db4171	https://p1.ssl.qhimgs1.com/t0112d70d1a39b0a3…	野营车,停止,侧面,道路,户外,科多巴,阿根廷	http
043d40c927a98da8f5a06e6f9eb22a03	https://ps.ssl.qhmsg.com/t0135fdf199af4248c9.jpg	房子,山,边缘,挪威	http
0462b9aee82cfe04e9469973a19fafa1	https://ps.ssl.qhmsg.com/t015d66735db50ad1d6.jpg	地点,苏塞克斯,英格兰,英国,欧洲	http
04986de3aaae0b8b2dba8744bc86044f	https://ps.ssl.qhmsg.com/t012b59ee7a85264b55.jpg	标识,文字,屋舍,箭头	http
04e1d0c52d2d8835c9f15d1ffd6b2f06	https://p1.ssl.qhimgs1.com/t0199c21916b2761f…	小屋,大提顿山,山峦,后面	http
04f52ae997b58860e69e151df908291e	https://ps.ssl.qhmsg.com/t01c2bb853e048be307.jpg	反射,水中,诺曼底,法国,欧洲	http
04f7ab9918a99e8cb33b01d55030b583	https://ps.ssl.qhmsg.com/t01bc41cba769b8e6e7.jpg	韦斯特波特,房子,梅奥,爱尔兰	http
05001267be1c40ef763e3c41b075a866	https://ps.ssl.qhmsg.com/t017a79598b15cfac98.jpg	房子,商店,巴纳韦,著名,古老,稻米梯田,山脉,区域,…	http

查看 MongoDB，下载成功的图片信息同样已成功保存，如图所示。

db.getCollection('images').find({})

localhost localhost:27017 images360

```
db.getCollection('images').find({})
```

images 0.005 sec. 0 50

Key	Value	Type
(1) ObjectId("597ca24515c2606454d...	{ 5 fields }	Object
_id	ObjectId("597ca24515c2606454d6aa2d")	ObjectId
id	96384384f2ca6186fffd3f111c11a4c2	String
url	https://ps.ssl.qhmsg.com/t01fcb3feb9b4e5b...	String
title	森林记	String
thumb	https://ps.ssl.qhmsg.com/sdr/238__/t01fcb3f...	String
(2) ObjectId("597ca24515c2606454d...	{ 5 fields }	Object
_id	ObjectId("597ca24515c2606454d6aa2e")	ObjectId
id	8b9cdb934e919b1d2367ed139b066a48	String
url	https://p3.ssl.qhimgs1.com/t010ce491d1853...	String
title	森林	String
thumb	https://p3.ssl.qhimgs1.com/sdr/238__/t010ce...	String
(3) ObjectId("597ca24515c2606454d...	{ 5 fields }	Object
(4) ObjectId("597ca24515c2606454d...	{ 5 fields }	Object
(5) ObjectId("597ca24515c2606454d...	{ 5 fields }	Object
(6) ObjectId("597ca24515c2606454d...	{ 5 fields }	Object
(7) ObjectId("597ca24515c2606454d...	{ 5 fields }	Object
(8) ObjectId("597ca24515c2606454d...	{ 5 fields }	Object
(9) ObjectId("597ca24515c2606454d...	{ 5 fields }	Object
(10) ObjectId("597ca24515c2606454...	{ 5 fields }	Object
(11) ObjectId("597ca24515c2606454...	{ 5 fields }	Object
(12) ObjectId("597ca24515c2606454...	{ 5 fields }	Object
(13) ObjectId("597ca24515c2606454...	{ 5 fields }	Object
(14) ObjectId("597ca24515c2606454...	{ 5 fields }	Object
(15) ObjectId("597ca24615c2606454...	{ 5 fields }	Object
(16) ObjectId("597ca24615c2606454...	{ 5 fields }	Object

这样我们就可以成功实现图片的下载并把图片的信息存入数据库了。

9. 本节代码

本节代码地址为：
https://github.com/Python3WebSpider/Images360。

10. 结语

Item Pipeline 是 Scrapy 非常重要的组件，数据存储几乎都是通过此组件实现的。请你务必认真掌握此内容。