

Natas Wargame Level 3 Writeup 与 robots.txt

转载

[a_18067](#) 于 2017-05-12 11:54:00 发布 51 收藏

文章标签: [爬虫](#)

原文链接: <http://www.cnblogs.com/liqiuhaio/p/6844874.html>

版权

```
<body>
  <h1>natas3</h1>
  <div id="content">
    ::before
    There is nothing on this page
    <!--No more information leaks!! Not even Google will ...-->
    ::after
  </div>
```

从HTML的注释代码来看,“google无法搜索到这个页面”->说明该网站很可能设置了防爬虫机制: robots.txt

以下是robots.txt的介绍(来自维基百科):

robots.txt (统一小写)是一种存放于[网站根目录](#)下的ASCII编码的[文本文件](#),它通常告诉网络[搜索引擎](#)的漫游器(又称[网络蜘蛛](#)),此网站中的哪些内容是不应被搜索引擎的漫游器获取的,哪些是可以被漫游器获取的。因为一些系统中的URL是大小写敏感的,所以robots.txt的文件名应统一为小写。robots.txt应放置于网站的根目录下。如果想单独定义搜索引擎的漫游器访问子目录时的行为,那么可以将自定的设置合并到根目录下的robots.txt,或者使用robots[元数据](#)(Metadata,又称元资料)。

robots.txt协议并不是一个规范,而只是约定俗成的,所以并不能保证网站的隐私。注意robots.txt是用字符串比较来确定是否获取[URL](#),所以目录末尾有与没有斜杠“/”表示的是不同的URL。robots.txt允许使用类似“Disallow: *.gif”这样的通配符^{[1][2]}。

其他的影响搜索引擎的行为的方法包括使用robots[元数据](#):

```
<meta name="robots" content="noindex,nofollow" />
```

这个协议也不是一个规范,而只是约定俗成的,有些搜索引擎会遵守这一规范,而其他则不然。通常搜索引擎会识别这个元数据,不索引这个页面,以及这个页面的链出页面。

例子:

允许所有的机器人:

```
User-agent: *
Disallow:
```

另一写法

```
User-agent: *
Allow:/
```

仅允许特定的机器人: (name_spider用真实名字代替)

```
User-agent: name_spider
Allow:
```

拦截所有的机器人:

```
User-agent: *
Disallow: /
```

禁止所有机器人访问特定目录:

```
User-agent: *
Disallow: /cgi-bin/
Disallow: /images/
Disallow: /tmp/
Disallow: /private/
```

仅禁止坏爬虫访问特定目录 (BadBot用真实的名字代替):

```
User-agent: BadBot
Disallow: /private/
```

禁止所有机器人访问特定文件类型^[2]:

```
User-agent: * Disallow: /*.php$ Disallow: /*.js$ Disallow: /*.inc$ Disallow: /*.css$
```

另外还有一些扩展指令。

于是访问根目录下的robots.txt文件:



```
User-agent: *
Disallow: /s3cr3t/
```

得到禁止所有爬虫 (spider, crawler) 访问的目录s3cr3t/:

Index of /s3cr3t

<u>Name</u>	<u>Last modified</u>	<u>Size</u>	<u>Description</u>
 Parent Directory		-	
 users.txt	2016-12-20 05:15	40	

Apache/2.4.10 (Debian) Server at natas3.natas.labs.overthewire.org Port 80

得到用户密码:

natas4:Z9tkRkWmpt9Qr7XrR5jWRkgOU901swEZ

总结：网站防止爬虫访问的目录或者文件可能含有敏感文件，这也是一个切入点。

转载于:<https://www.cnblogs.com/liqiuhaop/p/6844874.html>