

УДК 622

ПРИМЕНЕНИЕ ПАРСИНГА САЙТОВ В SEO С ИСПОЛЬЗОВАНИЕМ PYTHON

К.В. Иушина, студент гр. ПИМ-231, II курс

Научный руководитель – А.А. Тайлакова, к.т.н., доцент

Кузбасский государственный технический университет имени Т. Ф.

Горбачева, г. Кемерово

В современном мире оптимизация веб-ресурсов играет ключевую роль в обеспечении их высокой видимости в поисковых системах. Для эффективного продвижения сайтов SEO-специалистам необходимо анализировать их структуру, мета-данные, заголовки, канонические ссылки и другие параметры, влияющие на ранжирование. Однако ручной сбор такой информации может быть трудоемким и неэффективным, особенно при работе с большим объемом информации.

Одним из способов такого процесса является парсинг (parsing) — метод автоматического анализа веб-страниц для извлечения структурированной информации. Этот процесс, также известный как веб-скрапинг, позволяет значительно упростить сбор показателей. Например, вместо того чтобы вручную искать и копировать заголовки страниц и ссылки, можно использовать программный скрипт, который выполнит эту задачу автоматически и сохранит полученные данные в удобном формате.

На данный момент существует множество программ для парсинга, но они ограничены лимитами. Например, Screaming Frog SEO Spider - это программное обеспечение, которое сканирует сайты, анализирует мета-данные, статус индексации, ошибки 404, редиректы и многое другое. Но в бесплатной версии, она анализирует только 500 URL, а платный тариф стоит от 259 долларов в год.

Классические методы требуют значительных временных затрат и усилий, что вызывает необходимость в автоматизации процесса извлечения информации, сохранении ее в структурированном формате и проведении анализа на основе этих данных.

Предложенная методика основывается на использовании Python с библиотеками requests, BeautifulSoup и csv.

```
import requests
from bs4 import BeautifulSoup
from urllib.parse import urljoin
import csv
```

1. Функция `get_page_info` получает необходимые данные с заданного URL-адреса:

- Заголовок страницы извлекается из тега `<title>`.
- Мета-описание извлекается из тегов `<meta>` с атрибутом `name="description"`.
- Заголовки от H1 до H6 извлекаются с помощью цикла и `soup.find_all()`.
- Канонический URL проверяется через `<link rel="canonical">`.
- Установка флага `noindex` осуществляется на основе наличия соответствующего текста на странице.

```
try:
    response = requests.get(url, timeout=5)
    soup = BeautifulSoup(response.text, 'lxml')
    title = soup.title.string if soup.title else ''
    description = soup.find("meta", attrs={"name":
"description"})
    description = description["content"] if description
else ''
    h_tags = {f"H{level}": [h.get_text(strip=True) for
h in soup.find_all(f"h{level}")] for level in range(1,
7)}
    canonical = soup.find("link", rel="canonical")
    canonical = canonical["href"] if canonical else ''
    noindex = "noindex" in response.text.lower()
    page_format = response.headers.get("Content-Type",
"").split(";")[0]
```

2. Функция `get_all_links` находит все внутренние ссылки на заданном сайте и извлекает их. Она использует обход в глубину (DFS) для посещения каждого URL. Каждая страница анализируется на наличие ссылок. Непосещенные ссылки добавляются в очередь на дальнейшее изучение.

```
visited = set()
to_visit = {site_url}
all_links = set()
while to_visit:
    url = to_visit.pop()
    if url in visited:
        continue
    visited.add(url)
    try:
        response = requests.get(url, timeout=5)
        soup = BeautifulSoup(response.text, 'lxml')
```

```
for link in soup.find_all("a", href=True):  
    full_url = urljoin(url, link["href"])  
    if site_url in full_url and full_url not  
in visited:  
        to_visit.add(full_url)  
        all_links.add(full_url)
```

3. Основная функция main собирает ссылки, получает информацию о страницах и сохраняет результаты в CSV-файл.

```
all_urls = get_all_links(site_url)  
data = []  
for url in all_urls:  
    info = get_page_info(url)  
    if info:  
        data.append(info)  
  
    with open("site_data.csv", "w", newline="",  
encoding="utf-8") as csvfile:  
        fieldnames = ["URL", "Title", "Description",  
"Status Code", "Format", "Canonical", "Noindex", "H1",  
"H2", "H3",  
                        "H4", "H5", "H6"]  
        writer = csv.DictWriter(csvfile,  
fieldnames=fieldnames)  
        writer.writeheader()  
        writer.writerows(data)
```

Для запуска программы, необходимо ввести URL сайта, который нужно проанализировать (рис. 1).

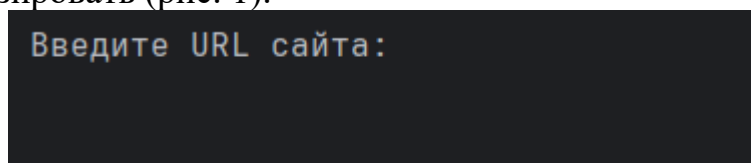


Рисунок 1 - Запуск программы.

После выполнения кода, результаты сохраняются в файл site_data.csv, который содержит информацию о сайте (рис. 2).

Рисунок 2 - Данные файла *site data.csv*.

Таким образом, автоматизация процесса сбора SEO-данных с помощью Python и его библиотек значительно упрощает анализ веб-ресурсов, сокращая время на ручной обход. Использование парсинга позволяет быстро извлекать ключевую информацию о страницах, такую как заголовки, мета-описания, канонические ссылки и другие важные параметры, влияющие на ранжирование в поисковых системах. Это особенно актуально для крупных сайтов, где ручной анализ становится неэффективным. Разработанный скрипт предоставляет удобный и доступный инструмент для SEO-специалистов, помогая им в оптимизации веб-ресурсов и повышении их конкурентоспособности в цифровой среде.

1. Парсинг сайтов на Python: для чего нужен и как написать скрипт [Электронный ресурс]. – Режим доступа: <https://blog.skillfactory.ru/parsing-saytov-na-python/>

3. The Python Standard Library [Электронный ресурс]. – Режим доступа: <https://docs.python.org/3/library/index.html>

4. Парсинг сайтов. «SITEANALYZER» как инструмент для проведения технического SEO- аудита сайтов [Электронный ресурс]. – Режим доступа: https://libeldoc.bsuir.by/bitstream/123456789/40206/1/Sitnik_Parsing.pdf