Яндекс

Автоматический сбор данных

Сергей Нурк

Разработчик

Владимир Батыгин

разработчик

АУ, Санкт-Петербург, 1 ноября 2010 года


План

- Введение
- MDR
- SinglePage
- Итоги



Введение





Clone Wars

Video

Games

Movies **Fans** Kids

Vault

Shop

More

Sign in

Databank:

By Category

By Appearance

Millennium Falcon



From the Movies

A legendary starship despite its humble origins and deceptively dilapidated exterior, the Millennium Falcon has factored into some of the Rebel Alliance's greatest victories over the Empire. On the surface, the Falcon looks like any other

Corellian freighter, with a saucer-shaped primary hull, a pair of forward cargo-gripping mandibles, and a cylindrical cockpit mounted to the ship's side.

Beneath its hull, though, the Falcon packs many powerful secrets. Its owners made "special modifications" on the freighter, boosting its speed, shielding and performance to downright illegal levels. Its weaponry has been upgraded to military-class quad laser turrets. To cover rapid escapes, the Falcon sports a ventrally mounted hatch-concealed antipersonnel repeating laser. Between its forward mandibles rest concussion missile launchers. The habitable interior of the vessel also has a few surprises, such as concealed scanner-proof smuggling compartments.

The Falcon pays a heavy price for its augmented performance, though. It is extremely recalcitrant and often unpredictable. Its reconditioned hyperdrive often fails. Its current captain, Han

STAR WARS profile

Appeared in:

IV V VI CW

Homeworld: Corellia

Size:

26.7 meters long

Weapon:

quad laser cannons, concussion missiles

Affiliation:

Smuggling, Rebel Alliance

Type:

YT-1300 freighter

Manufacturer:


Related News

Celebration V: Slave Leia 360 360° of Leia's Metal Bikini at Celebration VI Check out the second 360 view on the Millennium Falcon set!

Eat Lunch at Lightspeed: Star Wars Sandwich Cutters

Have lunch with Darth Vader and Han Solo with TIE fighter and Millennium Falcon sandwich cutters from Williams-Sonoma!

"This Is No Cave" Exclusive Print Now Available The fifth in The Empire Strikes Back 30 Anniversary Artwork Series is now available exclusively at StarWarsShop and limited to just 100 pieces!



Millennium Falcon



Name

Millennium Falcon

Homeworld

Corellia

Size

26.7 m

Weapon

- quad laser cannons
- concussion missiles



_STAR_WAR5 profile

Appeared in:

I II III IV V VI CW

Homeworld:

Corellia

Size:

26.7 meters long

Weapon:

quad laser cannons, concussion missiles



Вёрстка

Разнообразна Часто изменяется



Специализированные парсеры

На каждый сайт - свой



Нужна армия






Общие алгоритмы



Предполагают наличие на странице регулярной структуры

KIT NAME	<u>MANUFACTURER</u>	SCALE	MATERIAL
A-Wing Fighter	SMT	1.48	Resin
A-Wing Fighter	AMT/ERTL	1.48	Plastic
Aayla Secura	Nut-Hut Productions	1.6	Resin
Admiral Ackbar	Craft Master	1.14	Vinyl
Anakin Skywalker	Mojoresin	1.8	Resin
Anakin's Podracer	AMT/ERTL	1.32	Plastic
AT-AT	SMT	1.53	Resin
AT-AT	MPC/ERTL	1.100	Plastic



Я


Основные требования

- Простая настройка
- Простая поддержка
- Высокие показатели полноты и точности



Глава 1. MDR






Что надо получить

- MILLENNIUM FALCON
- Approx. Retail: \$179.99
- Item #: 87591
- Best known as the fastest ship in the Star Wars galaxy, piloted by Han Solo and Chewbacca ...



Исходный код страницы

```
<html><head> ... </head>
  <body>
     ... 
    MILLENNIUM FALCON
      Approx. Retail: $49.99
        Item #: 19647 
        The most famous ship ...
      MagnaGuard Fighter
      Approx. Retail: $24.99
         Item #: 87969 
        | G-series 100 ...
```



You Have Selected:

Brand:

Star Wars

Product Category: **M** Vehicles

R removes selection

Narrow Your Results

Brand

SpeedStars (1)

Transformers (1)

Product Category

Cars (1)

Remote Controlled (4) Spaceships (10)

Gender

Boys (16)

Both (1)

Price

Under \$10 (1)

Over \$100 (1)

\$10 - \$20 (4)

\$20 - \$30 (6)

\$30 - \$40 (2)

\$40 - \$50 (1)

\$50 - \$100 (2)

More Ways to Shop

Sort By: - select -

17 Items Found

Remote Control

Item #: 19647

Featuring.....More

Items Per Page: 10, 50

Star Wars SPEED STARS Millennium Falcon

Approx. Retail: \$49.99

12...Next >

Where to Buy STAR WARS 2



More Images

Star Wars The Clone Wars MagnaGuard Fighter

The most famous ship in the galaxy files into action! The

Millennium Falcon soars through space, taking the fight against the Empire everywhere it goes. This powerful starship may not look like much, but she's got it where it counts! Get ready for a battle of epic proportions!

Item #: 87969

IG-series 100 MagnaGuards - the drold bodyguards for General Grievous - fly specialized fighters as part of their protective duties for the cyborg general. The agile fighters respond to the demands of their drold pilots and are armed with missiles to repel attacks from Republic forces. Sleek.....More

Approx. Retail: \$24.99

Where to Buy STAR WARS



More Images

STAR WARS MILLENNIUM FALCON

Item #: 87591

/!/WARNING: CHOKING HAZARD-Small Parts. Not For Children Under 3 Years. Best known as the fastest ship in the Star Wars galaxy, piloted by Han Solo and Chewbacca, this detailed replica of the rebel spacecraft packs powerful secrets and special modifications - inside and out. Measuring more than.....More

Approx. Retail: \$179.99



More Ways to Buy STAR WARS



Star Wars The Clone Wars Radio Control Hailfire Droid

Item #: 93974

Clone troopers beware - the halffire drold is rolling into battle, packed with missiles and ready to attack! It cuts a fearsome path as it moves over the ground, blasting anything in its way. Watch out - this mobile battle droid easily changes direction to keep the clone trooper army on the run!More

Approx. Retail: \$59.99



More Ways to Buy STAR WARS

More Images



Star Wars The Clone Wars Republic V-19 Torrent Starfighter

Item #: 19696

After making its debut at the Battle of Geonosis, the Republic's V-19 Torrent assault fighter is used with effectivness throughout the Clone Wars, Jedi commanders lead clone-piloted V-19 Torrents into battle against vulture droids and Separatist forces. Launch yourself into action with this......More

Approx. Retail: \$24.99

Where to Buy STAR WARS

• Основные теги: table, tr, td, div, p, li ...

- Основные теги : table, tr, td, div, p, li ...
- Дисперсия. Считается количество тегов в сущности


- Основные теги: table, tr, td, div, p, li ...
- Дисперсия. Считается количество тегов в сущности
- Повторяющиеся паттерны

- Основные теги: table, tr, td, div, p, li ...
- Дисперсия. Считается количество тегов в сущности
- Повторяющиеся паттерны
- Доменно-специфичные эвристики

Сущность

- Все узлы имеют общего родителя
- Все узлы смежны








Области данных

- 2 и более сущности
- Сущности имеют общего родителя
- Сущности имеют одинаковую длину
- Сущности смежны
- Расстояние между сущностями меньше определенного порога




Области данных






Поиск кандидатов

- Спуск в глубину
- На каждом уровне пытаемся найти кандидата
 - Для этого производится подсчет расстояний между предполагаемыми сущностями




- (1, 2), (2, 3), (3, 4), (4, 5), (5, 6), (6, 7), (7, 8) ...
- (2, 3), (3, 4), (4, 5), (5, 6), (6, 7), (7, 8) ...
- (3, 4), (4, 5), (5, 6), (6, 7), (7, 8) ...
- (4, 5), (5, 6), (6, 7), (7, 8) ...
- (5, 6), (6, 7), (7, 8) ...






- (1, 2), (2, 3), (3, 4), (4, 5), (5, 6), (6, 7), (7, 8), (8, 9), (9, 10)
- (1-2, 3-4), (3-4, 5-6), (5-6, 7-8), (7-8, 9-10)
- (1-2-3, 4-5-6), (4-5-6, 7-8-9)



• (1, 2), (8, 9, 10), (3-4, 5-6, 7-8), (2-3, 4-5, 6-7)



<TRTDTD...TDTD>





```
< TR TD TD ... TD TD >


< TR (TD TD ( ... ) TD TD ) >


TD TD TD TD

TD TD TD
```



Расстояние Левенштейна






TR TD TD ... TD


TR TD TD ... TD TD

TR TD TD ... * TD = 1



Шинглы





• (1, 2), (8, 9, 10), (3-4, 5-6, 7-8), (2-3, 4-5, 6-7)




Выбор лучшей области данных

- Выбор самой большой
- Выбор самой узкой
- Выбор самой старшей
- Выбор самой первой
- Взвешивание по ключевым словам



Выбор лучшей области данных



• (1, 2), (8, 9, 10), (3-4, 5-6, 7-8), (2-3, 4-5, 6-7)



Сложности

• Недостаточно регулярная структура

Сложности

- Недостаточно регулярная структура
- Мало данных на странице

Сложности

- Недостаточно регулярная структура
- Мало данных на странице
- Много шума



Глава 2. SinglePage






Управляемая экстракция

- 1. Пользователь задает примеры
- 2. Система автоматически извлекает данные со всего сайта



Взгляд внутрь

- 1. По примерам строим шаблоны (один атрибут один шаблон)
- 2. Применяем шаблоны к остальным (подходящим) страницам





Гипотетические преимущества

- Быстрая настройка
- Не требуется разбираться в структуре страницы
- Структурированное извлечение нужной информации
- Устойчивость к изменениям вёрстки (пересоздание шаблонов)





Ограничения

- Отдельная страница на каждый объект
- Группа страниц с однотипной вёрсткой




Алгоритм






Позиционирование



- 1. Xpath
- 2. Шаблон в виде дерева



Millennium Falcon



Я


_STAR_WARS profile Appeared in: II III IV V VI CW Homeworld: Corellia Size: 26.7 meters long Weapon: quad laser cannons, concussion missiles

//ul/li[3]/span





Droid Control Ship



_STAR_WARS profile

Appeared in:
I II III IV V VI CW

Size:


3,170 meters diameter

Weapon:

20 quad laser cannons;



_STAR_WARS profile Appeared in: II III IV V VI CW Homeworld: Corellia Size: 26.7 meters long Weapon: quad laser cannons, concussion missiles



//ul/li[3]/span




_STAR_WARS profile Appeared in: II III IV V VI CW Homeworld: Corellia Size: 26.7 meters long Weapon: quad laser cannons, concussion missiles



//ul/li[3]/span >>> Size=20 quad laser...

TreePattern



STAR WARS profile

TreePattern

Appeared in:

I II III IV V VI CW


Size:

3,170 meters diameter

Weapon:

20 quad laser cannons;

4 turbolasers









Схема алгоритма

- Находим вхождения примеров
- Строим TreePattern, задающий положение узла
- Применяем TreePattern к остальным страницам




- Начинаем от мест вхождения примеров
- Синхронно движемся по деревьям, сравнивая узлы
- Накапливаем TreePattern



























Проблема

Millennium Falcon




<h1>Millennium Falcon</h1>

Droid Control Ship







Препятствия

- Сложности с вхождением примеров
- Неправильные страницы



Поиск вхождений


Millennium Falcon



Множественные вхождения

```
<title>StarWars.com | Millennium Falcon</title>
   <body>
       <!-- name -->
       <h1>Millennium Falcon</h1>
       <111>
          <!-- homeworld -->
          Homeworld:<span>Corellia</span>
                                                     4 варианта
          <!-- size/height -->
          Size:<span>26.7 meters long</span>
                                                     Выбираем лучший
<title>StarWars.com | Leviathan</title>
   <body>
      <!-- name -->
      <h1>Leviathan</h1>
       <!-- size/height -->
          Size:<span>600 meters long</span>
```

Фильтрация страниц





Глава 4. Итоги



Изменяющийся контент

Изменяется не везде

Хватает информации для формирования шаблонов


Есть возможность исправить пример

Статистика

Время создания < 20 мин

Предварительная оценка качества – несколько секунд

Полнота: 88% Точность: 92%





Нерешенные задачи

- Несколько объектов на странице
- Хорошая устойчивость к неоднородной верстке



Заключение

Полуавтоматические методы

- По качеству данных и универсальности сравнимы со сбором «в ручную»
- Сложность и время настройки минимальны

P.S. Экономьте Ваше время!



Вопросы





Нурк Сергей

Разработчик

111033, Россия, Санкт-Петербург, Свердловская наб., д. 44.

sergeynurk@yandex-team.ru