Data Journalism

Web Scraping - Selenium

InfoUma 2019-20 ***Andrea Marchetti***

Selenium

- Selenium nasce nel 2004 come tool per lo sviluppo di **test automatici per applicazioni web**
- Possibile scrivere script che simulano l'interazione umana con una applicazione web
- Con il tempo si dimostra un ottimo tool per progettare attività di scraping
- selenium.dev
- selenium wikipedia

Componenti di Selenium

1. Selenium IDE
2. Selenium Web Driver
3. Selenium Grid

Selenium IDE

Implementato come estensione di chrome e firefox

Consente di registrare, editare e riprodurre le azioni eseguite su di una pagina web

Selenium Web Driver

Selenium-WebDriver esegue chiamate dirette al browser usando il supporto nativo contenuto nei browser per l'automazione

Queste chiamate dipendono dal browser che stiamo usando, questo significa che dovremo installare un **Driver** differente per il browser che vogliamo usare e utilizzare una interfaccia differente di **WebDriver**

Webdriver è una raccomandazione W3C del 2018

Selenium GRID

Consente di parallelizzare il lavoro svolto con WebDriver

Riduzione del tempo

Selenium WebDriver

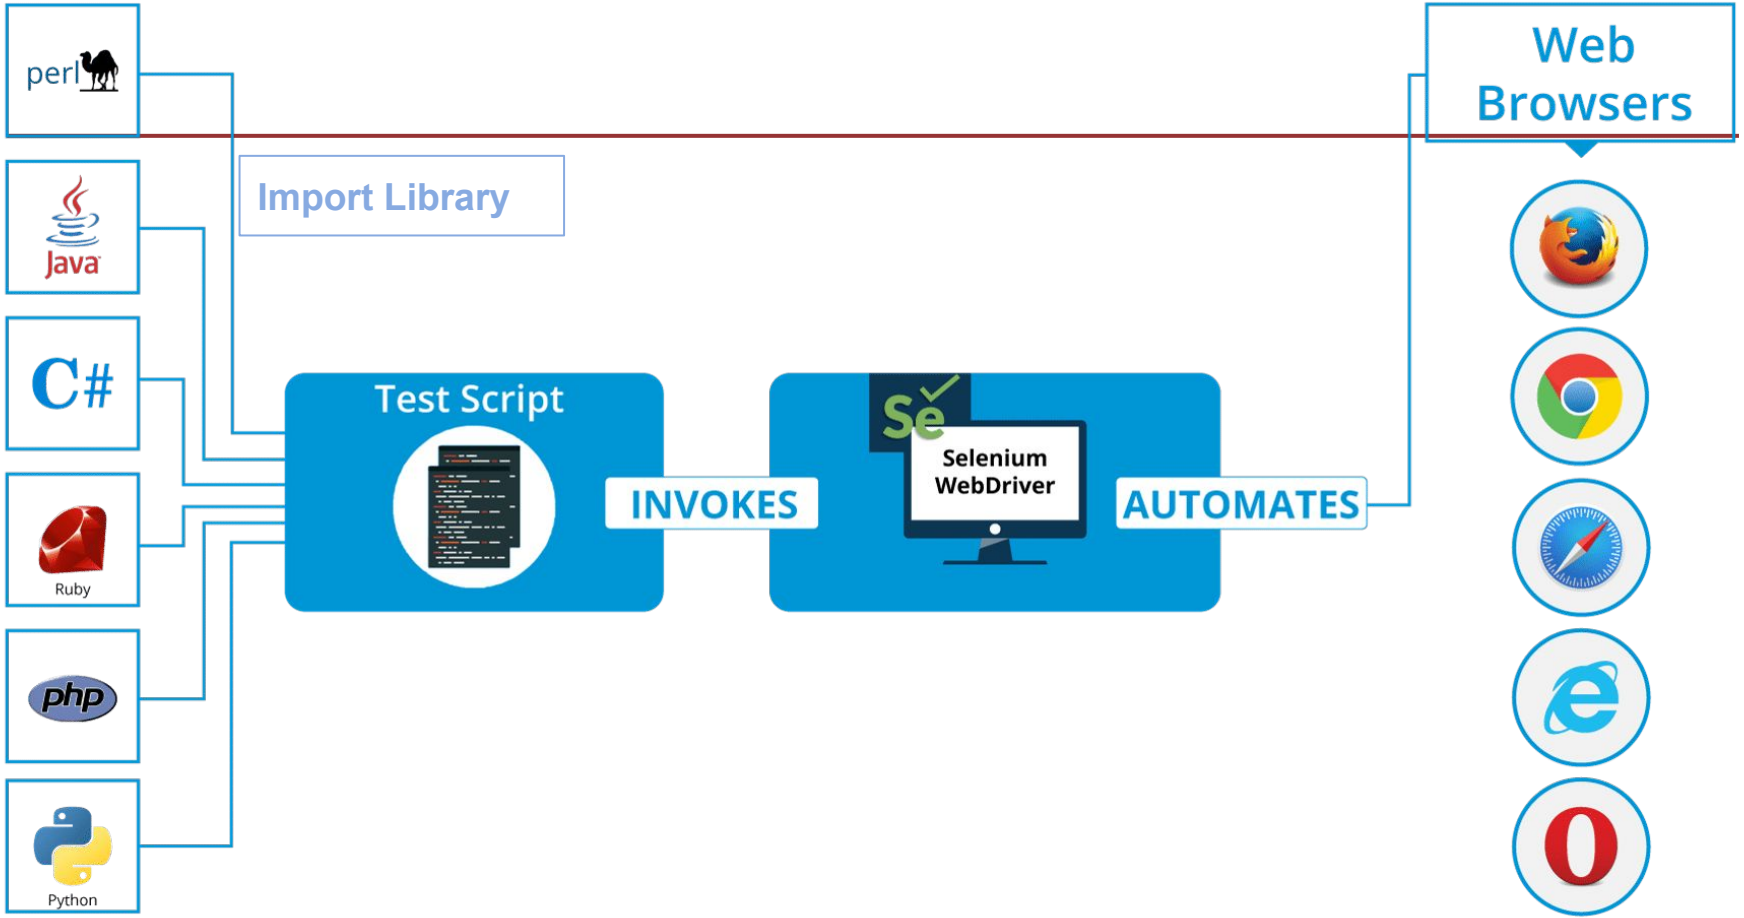
perl
Java
C#
Ruby
php
Python
Import Library
Test Script
INVOKES
Selenium
WebDriver
AUTOMATES
Web
Browsers

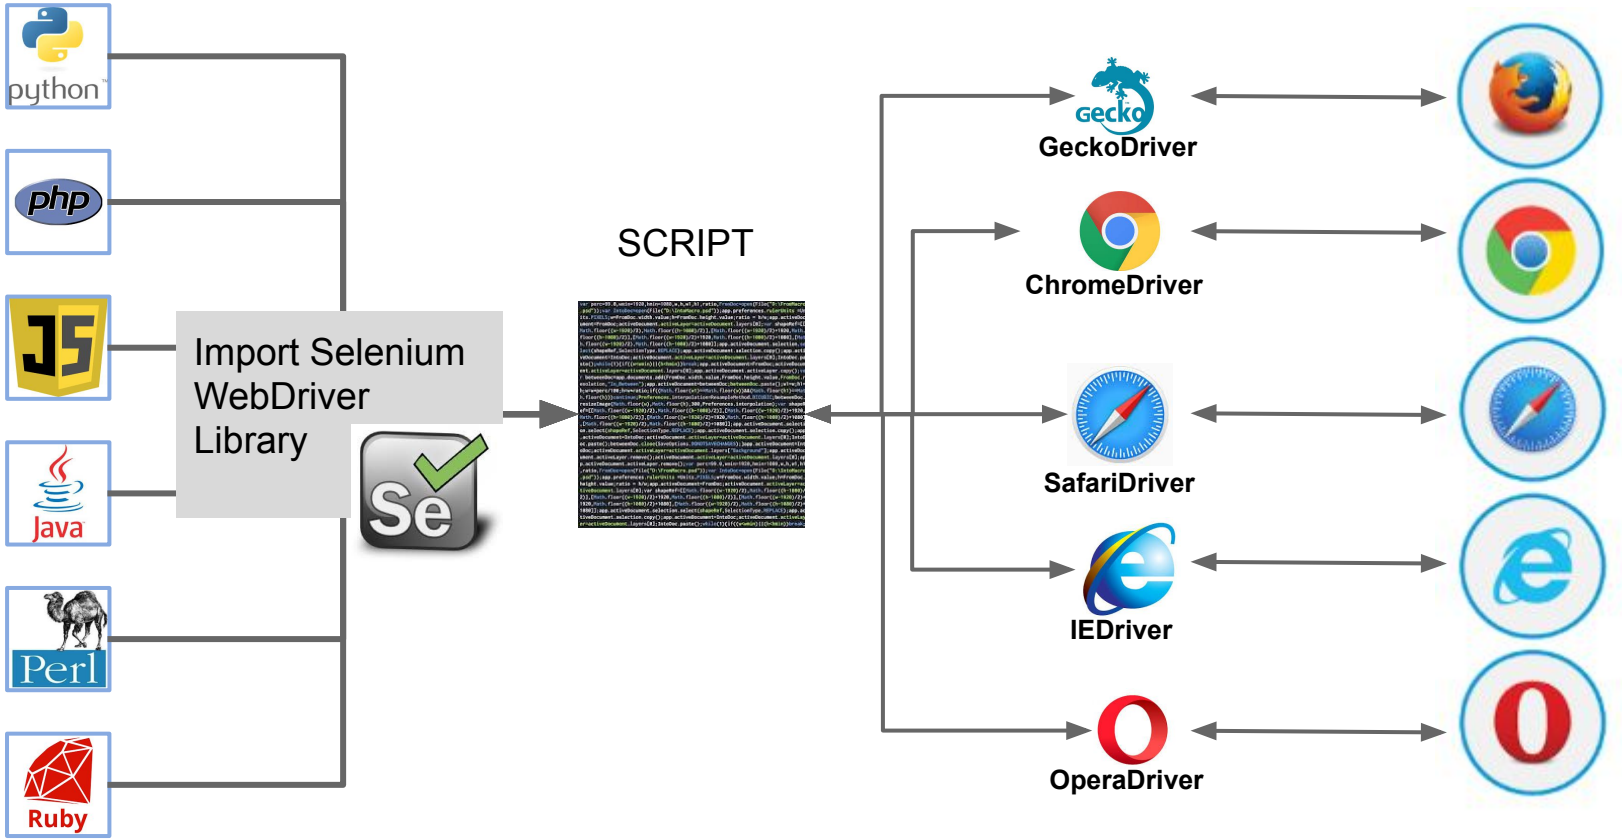
python
php
JS
Java
Perl
Ruby
Import Selenium WebDriver Library
Se
SCRIPT
Gecko
GeckoDriver
ChromeDriver
SafariDriver
IEDriver
OperaDriver

Driver dei maggiori browser

Implementano le specifiche WebDriver W3C

Requisiti per installare e usare i vari driver

- ChromeDriver
- GechoDriver (Firefox)
- Safari
- Edge
- InternetExplorer
- Opera

```python
from selenium import webdriver

# selenium ha le interfacce per i maggiori browser
driverChrome   = webdriver.Chrome()
driverFirefox  = webdriver.FireFox()
driverEdge     = webdriver.Edge()
driverSafari   = webdriver.Safari()
driverOpera    = webdriver.Opera()
driverExplorer = webdriver.Ie()
```

Lancio del driver di Chrome

```
from selenium import webdriver.Chrome

# Lancio del driver di Chrome che fa partire una pagina vuota del browser
driver  = Chrome()


# Istruisco il driver di Chrome a caricare una url
driver.get(“http://www.booking.com”)
```

Modalità Headless

Quando si invoca un driver di un browser questo fa partire una pagina del browser che poi verrà pilotata.

Con Chome e Firefox si può evitare questo comportamento con l'opzione Headless

Utile per velocizzare lo scraping

```
from selenium.webdriver import Chrome
from selenium.webdriver.chrome.options import Options

chromeOptions = Options()
chromeOptions.add_argument("--headless")

driver    = Chrome(options=chromeOptions)
driver.get(“htttp://www.repubblica.ir”)
```

Un primo esempio

```
from selenium import webdriver.Chrome
from selenium.webdriver.common.keys import Keys

driver = Chrome()
driver.get("http://www.google.com")

elem = driver.find_element_by_name("q")
elem.clear()
elem.send_keys("selenium")
elem.send_keys(Keys.RETURN)

driver.quit()
```

Lo script, tramite un'istanza di Chrome apre la pagina http://www.google.com e attraverso la searchbar cerca il termine selenium.


```
▶<style data-iml="1583918643441">…</style>
 <div class="pR49Ae gsfi" jsname="vdLsw"></div>
 <input class="gLFyf gsfi" maxlength="2048" name="q" type="text" jsaction=
 "paste:puy29d" aria-autocomplete="both" aria-haspopup="false"
 autocapitalize="off" autocomplete="off" autocorrect="off" autofocus role=
 "combobox" spellcheck="false" title="Cerca" value aria-label="Cerca" data-
 ved="0ahUKEwjA_dngjJLoAhWKDxQKHfaQB28Q39UDCAY"> == $0
</div>
▶<div class="dRYYxd">…</div>
```

Parsing e simulazione tastiera

```
elem = driver.find_element_by_name("q")
```

Il WebDriver offre diversi modi per trovare gli elementi presenti nella pagina. In questo caso localizziamo una element input text grazie al suo attributo name.

```
elem.clear()
elem.send_keys("selenium")
elem.send_keys(Keys.RETURN)
```

Per simulare la digitazione da tastiera utilizziamo il metodo send_keys(). Prima però, ci assicuriamo che non ci sia già del testo nell'input text svuotandolo tramite il metodo clear(). Tasti speciali come INVIO possono essere simulati grazie alla classe Keys.

WebDriver API for Python

Selenium With Python: documentazione

Trovare un elemento nella pagina

Il WebDriver fornisce diverse strategie per localizzare un elemento presente nella pagina.

```
driver.find_element_by_id('')
driver.find_element_by_name('')
driver.find_element_by_xpath('')
driver.find_element_by_link_text('')
driver.find_element_by_partial_link_text('')
driver.find_element_by_tag_name('')
driver.find_element_by_class_name('')
driver.find_element_by_css_selector('')
```

Tutti i metodi restituiscono un oggetto di tipo WebElement. Nel caso non esista un elemento corrispondente ai criteri della ricerca viene generata l'eccezione NoSuchElementException.

Trovare più elementi nella pagina

È possibile localizzare anche più elementi contemporaneamente.

```
driver.find_elements_by_name('')
driver.find_elements_by_xpath('')
driver.find_elements_by_link_text('')
driver.find_elements_by_partial_link_text('')
driver.find_elements_by_tag_name('')
driver.find_elements_by_class_name('')
driver.find_elements_by_css_selector('')
```

Tutti i metodi restituiscono una **lista** di oggetti di tipo WebElement.
Nel caso non esista nemmeno un elemento corrispondente ai criteri della ricerca viene restituita una lista di lunghezza 0.

WebElement

Il WebElement è un interfaccia che rappresenta un elemento nella pagina. Ci permette di interagire con l'elemento e di estrarne informazioni attraverso vari metodi.

```
webelement.clear()
webelement.click()
webelement.get_attribute('')
webelement.get_property('')
webelement.is_displayed()
webelement.is_enabled()()
webelement.is_selected()
webelement.screenshot('')
webelement.send_keys('')
webelement.submit()
webelement.value_of_css_property('')
```

WebElement

È fornito anche di attributi.

```
webelement.id
webelement.location
webelement.location_once_scrolled_into_view
webelement.parent
webelement.rect
webelement.screenshot_as_base64
webelement.screenshot_as_png
webelement.size
webelement.tag_name
webelement.text
```

Inoltre tutti i WebElement sono forniti degli stessi metodi di localizzazione presenti nel WebDriver.
Ricercare un elemento a partire da un altro elemento

Esempio

Femminile.Football.it

https://femminile.football.it/ricerca.php

Simulo un click sulla lettera Q che è un link

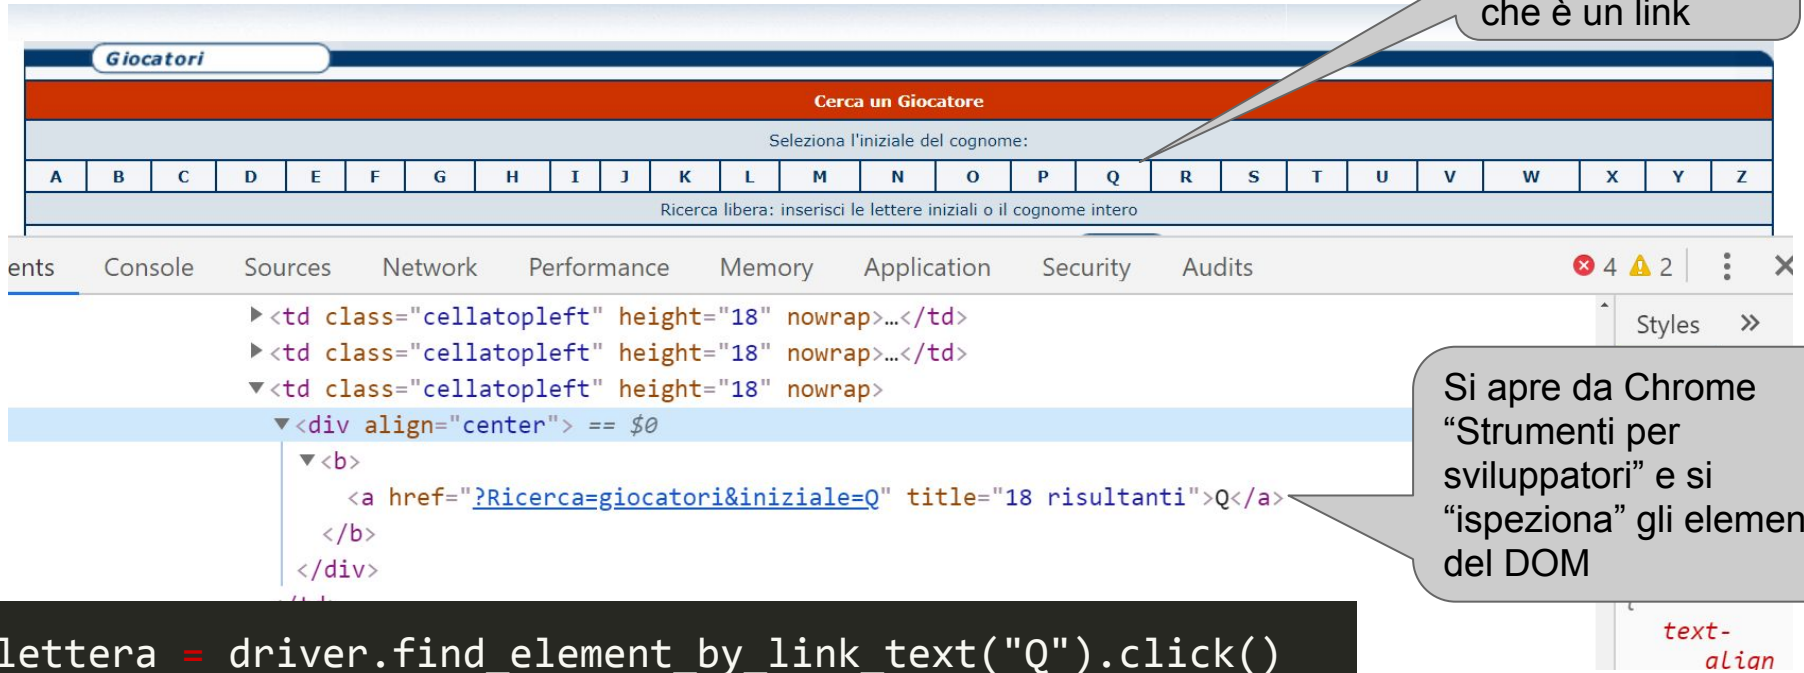

Si apre da Chrome “Strumenti per sviluppatori” e si “ispeziona” gli elementi del DOM

```
lettera = driver.find_element_by_link_text("Q").click()
```

Femminile.Football.it

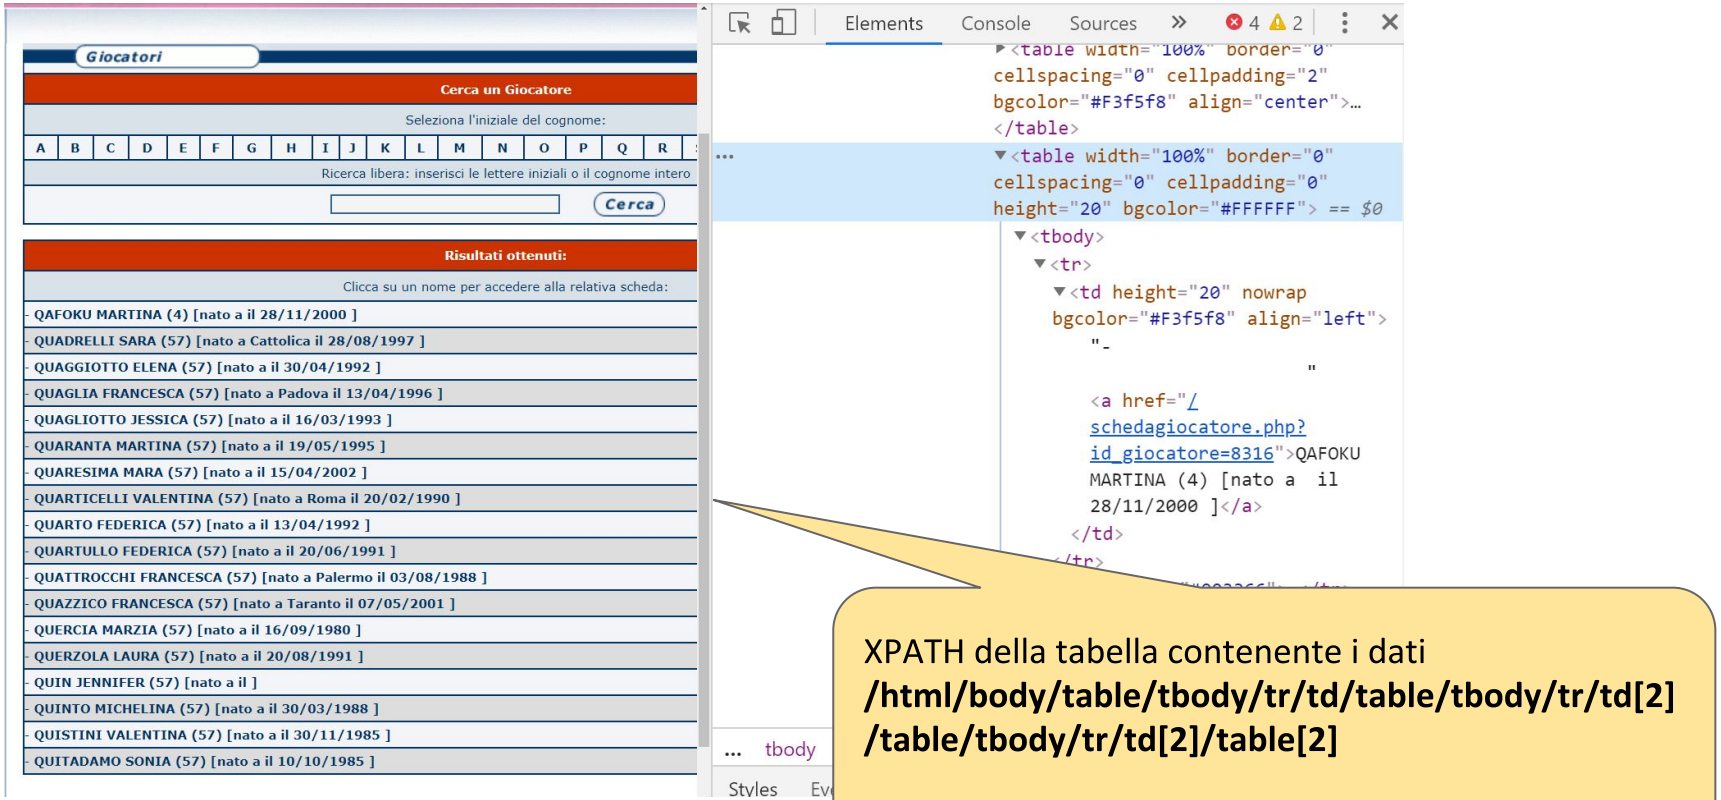

XPATH della tabella contenente i dati
/html/body/table/tbody/tr/td/table/tbody/tr/td[2]/table/tbody/tr/td[2]/table[2]

Scheda player

https://femminile.football.it/schedagiocatore.php?id_giocatore=2082

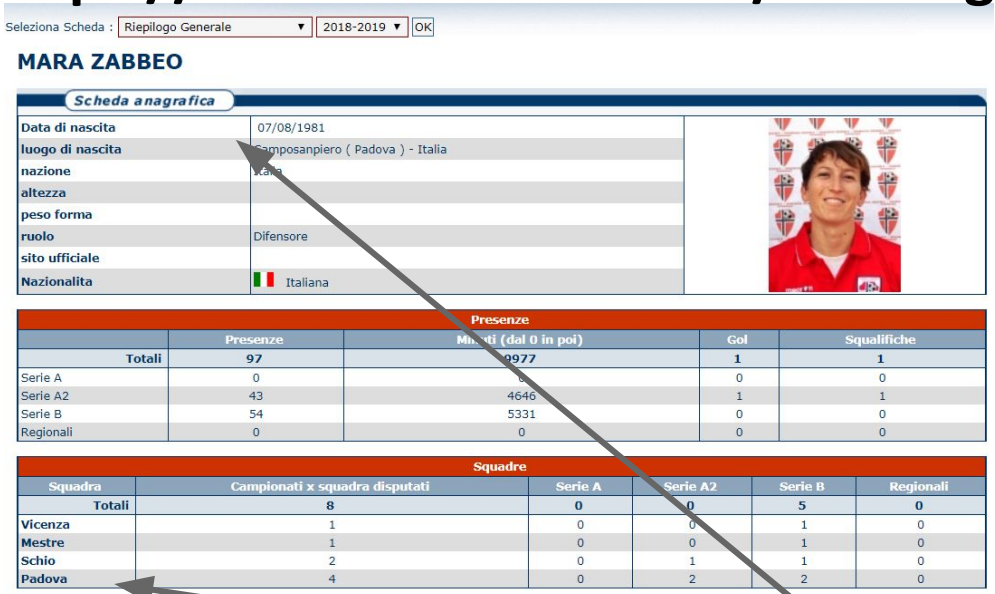

Seleziona Scheda : Riepilogo Generale 2018-2019 OK

MARA ZABBEO

Scheda anagrafica

Data di nascita	07/08/1981
luogo di nascita	Camposanpiero (Padova) - Italia
nazione	Italia
altezza	
peso forma	
ruolo	Difensore
sito ufficiale	
Nazionalita	Italiana

Presenze

	Presenze	Minuti (dal 0 in poi)	Gol	Squalifiche
Totali	**97**	**9977**	**1**	**1**
Serie A	0	0	0	0
Serie A2	43	4646	1	1
Serie B	54	5331	0	0
Regionali	0	0	0	0

Squadre

Squadra	Campionati x squadra disputati	Serie A	Serie A2	Serie B	Regionali
Totali	**8**	**0**	**0**	**5**	**0**
Vicenza	1	0	0	1	0
Mestre	1	0	0	1	0
Schio	2	0	1	1	0
Padova	4	0	2	2	0

Cambiando id ottengo i dati di una calciatrice.

getPlayerData(id)

/html/body/table/tbody/tr/td/table/tbody/tr/td[2]/table[**3**]/tbody/tr[1]/td[2]/table//tr

/html/body/table/tbody/tr/td/table/tbody/tr/td[2]/table[**5**]/tbody/tr[1]/td[2]/table//tr

Espressioni regolari in Python

Python string methods

Python fornisce delle funzioni per manipolare le stringhe le più usate sono:

- `split('-')` `# prende una stringa e restituisce una lista di stringhe`
- `strip()` `# elimina gli spazi bianchi marginali`
- `replace()` `# sostituisce una sottostringa con un altra`

Le altre possono essere trovate su w3schools

Python Espressioni Regolari

```
import re # importare la libreria
```

match

restituisce un'istanza di MatchObject se zero o più caratteri all'inizio della stringa corrispondono al pattern. È comunque possibile specificare una posizione da cui iniziare la ricerca diversa dalla testa della stringa, e anche un limite superiore). Restituisce None se la stringa non corrisponde al pattern.

search

scandisce la stringa cercando una corrispondenza con il pattern e restituisce l'istanza MatchObject corrispondente. Restituisce None se in nessuna posizione la stringa corrisponde al pattern. Anche qui è possibile specificare un punto d'inizio e di termine per la ricerca come per match.

split

in breve divide la stringa secondo le occorrenze del pattern e restituisce le porzioni ottenute come lista.

escape

prende in ingresso una stringa e la restituisce con i caratteri alfanumerici protetti da barre oblique inverse.

sub

restituisce la stringa ottenuta sostituendo alle occorrenze non sovrapposte del pattern l'entità rimpiazzo, che può essere una stringa o una funzione, eventualmente per un numero di volte prefissato.

Sintassi Espressioni Regolari

Character	Description
[]	A set of characters
\	Signals a special sequence (can also be used to escape special characters)
.	Any character (except newline character)
^	Starts with
$	Ends with
*	Zero or more occurrences
+	One or more occurrences
{}	Excactly the specified number of occurrences
|	Either or
()	Capture and group

Regular Expressions

documentazione

test on regular expression tester online

Save a list of dictionary to file


```
import json
with open('playersDB.json', 'w') as jsonFile:
    json.dump(playersDB, jsonFile)
```


```
import csv
keys = playersDB[0].keys() # Recupero i nomi dei campi dal primo dictionary
with open('playersDB.csv', 'w', newline='') as csvFile:
    dict_writer = csv.DictWriter(csvFile, keys) # imposto i nomi dei campi
    dict_writer.writeheader()                   # scriva la prima riga
    dict_writer.writerows(playersDB)            # scrivo i dati
```

Attese in Selenium

documentazione

- contenuti diversi possono essere caricati sulla pagina con tempi diversi
  - la diffusa presenza di tecnologie come AJAX rende frequente questa possibilità
- la ricerca di un elemento non ancora presente solleva un'eccezione
- la gestione delle attese durante lo scraping può risolvere questi problemi
- inserire attese può prevenire anche possibili **banning** da parte del server

Selenium WebDriver

Fornisce due tipi di waits

Esplicita

Implicita

WebDriverWait

Selenium WebDriver fornisce due tipi di wait;

- Esplicita
  - Aspetta finché si verifica una certa condizione prima di procedere con la ricerca
- Implicita
  - Ripete la ricerca ad intervalli di tempo regolari (POLL) per un certo periodo di tempo

WebDriverWait Esplicita

```
from selenium.webdriver.support.ui import WebDriverWait

elem = WebDriverWait(driver, tempo).until(condizione)
```

nel dettaglio, l'esecuzione riprende se:

- si verifica la condizione specificata
- si raggiunge un tempo massimo per l'attesa

Expected Conditions

- è possibile specificare la propria condizione andando a definire delle classi Python opportune
- sono già previste una serie di condizioni di uso comune che possono essere usate direttamente:
  - *visibility_of_element_located*
  - *element_to_be_clickable*
  - *text_to_be_present_in_element*
  - *…*

```
from selenium.webdriver.support import expected_conditions as EC

elem = WebDriverWait(driver, tempo)
```

Selezione elementi

- il modo più semplice per selezionare elementi all'interno di una condizione è tramite la cosiddetta classe By
- è uno dei metodi previsti in Selenium per la selezione degli elementi
- tramite la classe By è possibile specificare numerosi criteri di selezione:
  - *By.ID*
  - *By.XPATH*
  - *By.CLASS_NAME*
  - *By.CSS_SELECTOR*
  - …

Utilizzo della classe By

```
from selenium.webdriver.support.ui import WebDriverWait
from selenium.webdriver.support import expected_conditions as EC
from selenium.webdriver.common.by import By


driver = webdriver.Firefox()
driver.get('http://www.mypage.com')

wait = WebDriverWait(driver, 10)

try:
    element = wait.until(EC.presence_of_element_located(
    (By.CSS_SELECTOR, "span.titolone")))
```

WebDriverWait Implicita

```
from selenium import webdriver


driver = webdriver.Firefox()
driver.implicitly_wait(10) # 10 seconds
driver.get("http://somedomain/url_that_delays_loading")
myDynamicElement = driver.find_element_by_id("myDynamicElement")
```