



Web Scraping - Playwright



InfoUma 2024/25 **Andrea Marchetti**

Cos'è Playwright

Sistema di Automazione di browser (**Chrome, Edge, Firefox, Safari**)

Funzionamento **headless** o con **interfaccia grafica**

Perfetto per **web scraping** e **test automatici**

Supporto a **Python, JavaScript, Java**, e altri linguaggi

Cos'è Playwright

Posso scrivere un **programma** che simula il comportamento umano per

- aprire una finestra del browser,
- navigare in una pagina web
- compilare campi di input
- fare click sui pulsanti
- gestire le finestre di dialogo

Storia di Playwright

- **2017: Google** sviluppa **Puppeteer**, una libreria per automatizzare esclusivamente Chrome.
- **2020: Microsoft** introduce **Playwright**, derivato da Puppeteer, che supporta più browser (Chrome, Edge, Firefox, Safari).
- Rapidamente adottato dalla community grazie alle prestazioni elevate e alla semplicità d'uso.

Playwright Vs Selenium

Prestazioni elevate: È generalmente più veloce e meno pesante di Selenium.

Facilità d'uso: Configurazione più semplice e intuitiva.

Gestione automatica di caricamenti e attese: Riduce la necessità di espliciti wait per elementi.

Multi-browser integrato: Non richiede setup aggiuntivi per browser diversi.

Installazione

Assicuratevi di avere Python 3.7+ installato

Installa Visual Studio Code da

code.visualstudio.com

Installa l'estensione Python in VS Code

Installazione

Da Vs Code apri un terminale

```
python -m venv .venv # Crea un ambiente virtuale chiamato ".venv"  
.venv\Scripts\activate # Attiva l'ambiente  
pip install playwright # installa Playwright  
playwright install chromium # installa Chrome/Edge
```

Usa l'ambiente virtuale in VS Code

- Apri il file `.venv/bin/python` (Mac/Linux) o `venv\Scripts\python.exe` (Windows).
- Premi `Ctrl + Shift + P` e digita "Python: Select Interpreter".
- Scegli l'interprete Python dell'ambiente virtuale (venv).

Installazione

```
pip install playwright  
playwright install
```

Il primo comando installa la libreria Python per interagire con Playwright.

Il secondo comando installa i browser necessari al funzionamento di Playwright.

Test installazione

```
from playwright.sync_api import sync_playwright

with sync_playwright() as p:
    browser = p.chromium.launch(headless=True)
    page = browser.new_page()
    page.goto("https://example.com")
    print("Titolo della pagina:", page.title())
    browser.close()
```

Demo

Dataroom di Milena Gabanelli

<https://www.corriere.it/dataroom-milena-gabanelli/>

Primo Esempio

```
from playwright.sync_api import sync_playwright

def scrape_page(url):
    with sync_playwright() as p:
        browser = p.chromium.launch(headless=False)
        page = browser.new_page() # Apre una nuova pagina
        page.goto(file_path) # Vai su URL

        # trova tutti i tag <li> nella pagina
        lista_elementi = page.locator('li')

        # Cicla e stampa il testo di ogni elemento <li>
        for i in range(lista_elementi.count()):
            provincia = lista_elementi.nth(i).inner_text()
            print(f"Elemento {i+1}: {provincia}")

        # chiusura del browser
        browser.close()
```

Regione Toscana

- Arezzo
- Firenze
- Grosseto
- Livorno
- Lucca
- Massa-Carrara
- Pisa
- Pistoia
- Prato
- Siena

Note

Il metodo `locator('li')` seleziona tutti gli elementi `<li>` presenti sulla pagina.

Utilizzando il metodo `.count()` ottieni il numero totale degli elementi trovati.

Puoi accedere ad ogni elemento individualmente con `.nth(indice)`.

Modalità Headless

```
browser = p.chromium.launch(headless=False|True)
```

headless = True

utile in fase iniziale per testare cosa fa l'applicazione

headless=False

una volta che l'applicazione è pronta

Metadati della pagina

```
page.title()           # Titolo della pagina
page.url               # URL della pagina
page.content()         # sorgente html della pagina
page.screenshot(path="screenshot.png") # Salva uno screenshot della pagina
```

Tutti i modi per individuare elementi HTML con Playwright

Modi x individuare elementi HTML

Sintassi Generale

```
page.locator( 'selettore' )
```

Modi x individuare elementi HTML

1 Selettori CSS

```
page.locator( 'div.classe' )
```

```
page.locator( 'ul#idlista.classe > li.classe' )
```

Modi x individuare elementi HTML

2 Selettori XPath

```
page.locator( '//ul[@id="Toscana"]/li' )
```

```
page.locator( '//li' )
```

Modi x individuare elementi HTML

3 Selezione per testo

```
page.locator("text=Firenze")  
page.locator("li", has_text="Firenze")  
page.get_by_text("Firenze", exact="True")
```

Modi x individuare elementi HTML

4 Selezione tramite ruoli ARIA (Accessibilità)

```
# es. Ruolo: button, link, checkbox, radio, listitem ecc.  
page.get_by_role('listitem', name='Firenze')
```

Modi x individuare elementi HTML

5 Selezione per placeholder (per input)

per campi input con placeholder definito

```
<!-- Input  
<div class  
  <label  
  <input  
</div>
```

Email

nome@example.com">

```
page.get_by_placeholder(' nome@example.com')
```

Modi x individuare elementi HTML

6 Selezione tramite label

per elementi associati a una label esplicita

```
page.get_by_label(' Provincia')
```

Modi x individuare elementi HTML

7 Selezione tramite Alt-text (per immagini)

per elementi immagine

```
page.get_by_alt_text(' Logo')
```


Modi x individuare elementi HTML

8 Selezione per attributi personalizzati (data-attributes)

```
<li data-provincia="Firenze">Firenze</li>
```

```
page.locator('li[data-provincia="Firenze"]')
```

Modi x individuare elementi HTML

9 Selezione del primo, ultimo, n-esimo

```
page.locator('ul#Toscana > li').first  
page.locator('ul#Toscana > li').last  
page.locator('ul#Toscana > li').nth(3)  # terzo elemento
```

Modi x individuare elementi HTML

10 Concatenazione

```
page.locator('ul#Toscana').locator(':text("Firenze")')  
page.get_by_text('Firenze').locator('xpath=..') # genitore
```

Conclusioni

Selettore CSS: standard, semplice e leggibile.

XPath: potente, ma meno leggibile, per selezioni complesse.

Concatenazioni: per elementi annidati

Documentazione CSS Selector, XPath

[CSS Selectors Reference](#) w3schools

[Try CSS Selector](#) Test di espressioni XPath

[XPath Syntax](#) w3schools

[XPath](#) Test di espressioni XPath

Indietro

```
> <div id="rcsad_TopLeft_wrapper">... </div>
<!--@ESI generic END-->
▼ <main data-switch id="l-main">
  ▼ <div class="wrapper has-wall is-mr-t-10">
    ▼ <div class="container">
      ▼ <section class="body-section">
        ▼ <div class="columns" rcs-mobile-class="columns"> flex
          ▼ <div class="column is-8 is-pd-t-0" rcs-mobile-class="column">
            ▼ <div id="m16487-16472-16488">
              ▼ <div class="listing contentNews-listing latest-listing">
                <div class="box-title"> </div>
                ▼ <div class="bck-media-others listing">
                  ▼ <div class="bck-media-news">
                    ▼ <div class="media-news__content" rcs-mobile-class="media-news__content">
                      <span class="overtitle-art is-small-black is-mr-t-10">...
                        > <h4 rcs-mobile-class="title-art is-xsmall is-listing">
                          > <div class="media-news__image">... </div>
                          > <div class="media-news__footer">... </div>
                        </div>
                      > <div class="bck-media-news has--border-top">... </div>
                      > <div class="bck-media-news has--border-top">... </div>
                      > <div class="bck-media-news has--border-top">... </div>
                      > <div class="bck-media-news has--border-top">... </div>
                    </div>
                    > <div class="bck-media-others listing">... </div>
                    > <div class="bck-media-others listing">... </div>
                    > <div class="js-block-news is-hidden">... </div>
                    > <div class="js-block-news is-hidden">... </div>
                    > <div class="js-block-news is-hidden">... </div>
                    > <div class="js-block-news is-hidden">... </div>

```

Chiedi all'AI

Aggiungi attributo

Modifica attributo

Modifica come HTML

Duplica elemento

Elimina elemento

Taglia

Copia

Incolla

Nascondi elemento

Forza stato

Interrompi ai punti di

Espandi in modo ricorsivo

Comprimi secondari

Acquisisci screenshot del nodo

Scorri finché l'elemento diventa visibile

Imposta lo stato attivo

Impostazioni badge

Memorizza come variabile globale

li-listing category-listing

AROOM == \$0
t-hp is-medium is-line-h-10

onale-listing view-list">

Copia elemento

Copia outerHTML

Copia selector

Copia percorso di JavaScript

Copia stili

Copia XPath

Copia XPath completo

Ws_content" Overtitle-art is

32

**#m24721-24706-24722 > div >
div:nth-child(2) > div:nth-child(1) >
div > span**

**//*[@id="m24721-24706-24722"]/div/
div[2]/div[1]/div/span**



DATAROOM

di Milena Gabanelli

INNOVAZIONE POLITICA SANITA' AMBIENTE MONDO ECONOMIA SOCIETA'

div.bck-media-news 655.99 x 637.02

DATAROOM

Criptovalute, chi guadagna e chi perde



di Francesco Bertolino e Milena Gabanelli

Dopo il Bitcoin è nato un mercato da 3.300 miliardi di dollari. Il riciclaggio e la fregatura del Dogecoin, esaltato da Musk. Cosa sono gli stablecoin e come si salvano ai piani di Trump.

Cerca in Dataroom



DATAROOM

Come Trump sta demolendo la democrazia negli Usa

di Milena Gabanelli e Giuseppe Sarcina

Il potere si regge sul sistema dei «pesi e contrappesi» ma Trump ora controlla Congresso e Corte Suprema. Nominati in posti

```
Elementi Console Sorgenti Rete Prestazioni Memoria >>
<!--@ESI @querystring=
[env=prd&device=desktop&cmsType=xalok&section_level1=dataroom&section_level2=defau
includes/2019/SSI/adv/component/topleft/default.shtml]@ -->
<!--@ESI section_level1 [dataroom] -->
<!--@ESI section_level2 [default] -->
<!--@ESI section_level3 [default] -->
<div id="rcsad_TopLeft_wrapper">...</div>
<!--@ESI generic END-->
<main data-switch id="l-main">
  <div class="wrapper has-wall is-mr-t-10">
    <div class="container">
      <section class="body-section">
        <div class="columns" rcs-mobile-class="columns">flex
          <div class="column is-8 is-pd-t-0" rcs-mobile-class="column is-12">
            <div id="m24721-24706-24722">
              <div class="listing contentNews-listing latest-listing dataroom-milena-gabanelli-
                <div class="box-title"></div>
                <div class="bck-media-others listing">
                  ...
                  <div class="bck-media-news">== $0
                    <div class="media-news__content" rcs-mobile-class="media-news__content">
                      <span class="overtitle-art is-small-black is-mr-b-8 has-text-punch">DATARC
                      <h4 rcs-mobile-class="title-art is-xsmall is-line-h-11" class="title-art-l
                      <div class="media-news__image">...</div>
                      <div class="media-news__footer">...</div>
                    </div>
                    <div class="bck-media-news has--border-top ">...</div>
                    <div class="bck-media-news has--border-top ">...</div>
                    <div class="bck-media-news has--border-top ">...</div>
                    <div class="bck-media-news has--border-top ">...</div>
                  </div>
                  <div class="bck-media-others listing">...</div>
                  <div class="bck-media-others listing">...</div>
                  <div class="js-block-news is-hidden">...</div>
                  <div class="js-block-news is-hidden">...</div>
                </div>
              </div>
            </div>
          </div>
        </div>
      </section>
    </div>
  </div>
</main>
```


Interazione con Form elements

Inserisce "Testo di esempio".

```
page.locator("input#text-input").fill("Testo di esempio")
```

Seleziona l'opzione con value "opzione2".

```
page.locator("select#select").select_option("opzione2")
```

Seleziona il radio button con id "radio2".

```
page.locator("input#radio2").check()
```

Clicca sul pulsante di submit per inviare il form.

```
page.locator("button[type='submit']").click()
```

Spiegazione Demo

Dataroom di Milena Gabanelli

DataRoom

```
from playwright.sync_api import sync_playwright

url = "https://www.corriere.it/dataroom-milena-gabanelli/"

with sync_playwright() as p:
    browser = p.chromium.launch(headless=False)
    page = browser.new_page() # Apre una nuova pagina
    page.goto(url) # Vai su URL

    # Accetta cookie (se appare popup)
    try:
        page.click('button:text("ACCETTA E CONTINUA")')
    except:
        pass # ignora se il popup non appare
```

DataRoom

```
# Trova tutti i tag <div> con classe "bck-media-news"
news = page.locator('div.bck-media-news')

# Cicla su news e crea un record per ogni new
results = []
for i in range(news.count()):
    results.append({
        'titolo': news.nth(i).locator('h4').inner_text().strip(),
        'url'    : news.nth(i).locator('h4>a').get_attribute('href'),
        'autori' : news.nth(i).locator('span.author-art').inner_text().strip(),
        'desc'   : news.nth(i).locator('p.subtitle-art').inner_text().strip()
    })
```

DataRoom

```
import pandas as pd

# Salva i risultati su file CSV con pandas
df = pd.DataFrame(results)
df.to_csv('notizie.csv', index=False)

browser.close() # Chiude il browser
```

Risorse utili e documentazione

Documentazione ufficiale:

playwright.dev/python

Repository GitHub:

github.com/microsoft/playwright-python