



ΑΛΕΞΑΝΔΡΕΙΟ Τ.Ε.Ι ΘΕΣΣΑΛΟΝΙΚΗΣ
ΣΧΟΛΗ ΤΕΧΝΟΛΟΓΙΚΩΝ ΕΦΑΡΜΟΓΩΝ
ΤΜΗΜΑ ΠΛΗΡΟΦΟΡΙΚΗΣ



ΠΤΥΧΙΑΚΗ ΕΡΓΑΣΙΑ

Επισκόπηση των γλωσσών
προγραμματισμού για εξόρυξη δεδομένων
και ανάπτυξη τέτοιου προγράμματος για τον
ιστοχώρο του χρυσού οδηγού.

Θεμελιώδεις έννοιες

Τι είναι η εξόρυξη
δεδομένων από το
διαδίκτυο;

Είναι μια αυτοματοποιημένη διαδικασία άντλησης πληροφοριών και δεδομένων
από μια ή περισσότερες ιστοσελίδες.

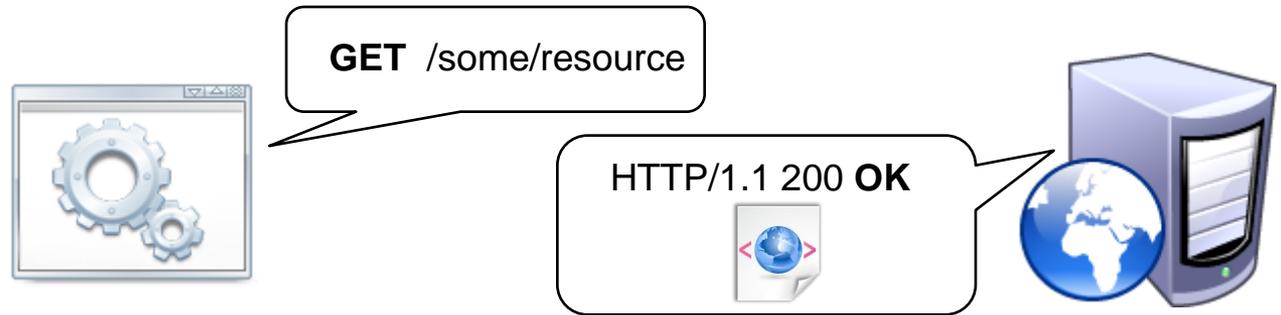


Θεμελιώδεις έννοιες

Τι είναι η εξόρυξη
δεδομένων από το
διαδίκτυο;

Στάδιο 1ο'
(Ανάκτηση του
περιεχομένου των
ιστοσελίδων)

Είναι μια αυτοματοποιημένη διαδικασία άντλησης πληροφοριών και δεδομένων από μια ή περισσότερες ιστοσελίδες.

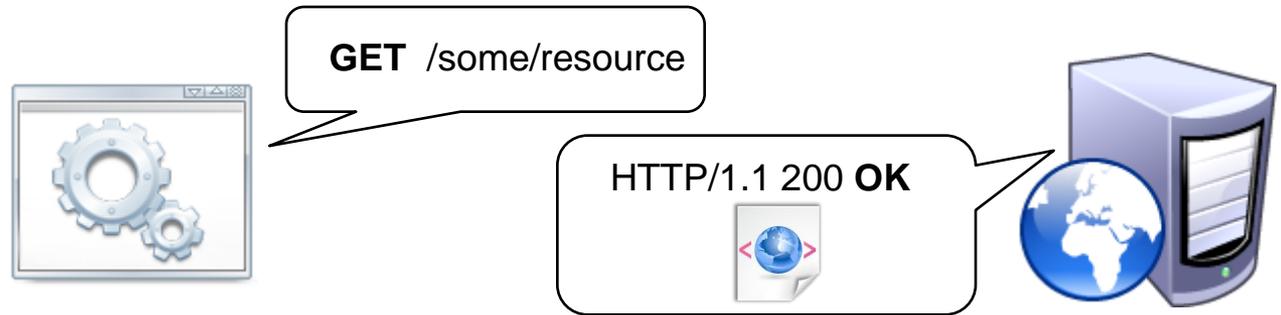


Θεμελιώδεις έννοιες

Τι είναι η εξόρυξη
δεδομένων από το
διαδίκτυο;

Είναι μια αυτοματοποιημένη διαδικασία άντλησης πληροφοριών και δεδομένων
από μια ή περισσότερες ιστοσελίδες.

Στάδιο 1ο'
(Ανάκτηση του
περιεχομένου των
ιστοσελίδων)



Στάδιο 2ο'
(Εξαγωγή και
αποθήκευση
των χρήσιμων
δεδομένων)



Συγκεντρωτικός πίνακας...

Χρήσιμες βιβλιοθήκες, κλάσεις και συναρτήσεις σε γνωστές γλώσσες προγραμματισμού

	URL fetching	HTML Parsing	Regexp
Ruby	open-uri rest-open-uri	Htree/ReXML Hpricot RubyfulSoup WWW::Mechanize ScRUBYt! Watir	Regexp
Perl	LWP::Simple	HTML::TreeBuilder WWW::Mechanize Web::Scraper	//, =~, ...
Python	urllib urllib2	HTMLParser BeautifulSoup lxml Mechanize scrape.py	re
PHP	fopen loadHTMLFile	Simple HTML DOM Parser htmlSQL DOMDocument+Xath	preg_match preg_match_all ...
Java	java.net.URL	JSoup	Java.util.regex
.NET	System.Net.HTTPWeb Request	HTMLAgilityPack	System.Text.RegularE xpressions



Κανονικές Εκφράσεις

```
<td>Current <strong>UTC</strong> (or GMT/Zulu)-time used: <strong  
id="ctu">Saturday, March 5, 2011 at 21:54:12</strong><br>  
<span class="small">UTC is Coordinated Universal Time, GMT is  
Greenwich Mean Time.</span></td>
```

```
perl -MLWP::Simple -le  
'$c = get("http://timeanddate.com/worldclock/");  
$c =~ m@<strong id="ctu">(.*?)</strong>@ and print $1'
```

```
#Saturday, March 5, 2011 at 21:54:12
```

Μειωνεκτήματα:

- Εκφράσεις 'εύθραυστες' ακόμα και με μικρές αλλαγές στον HTML κώδικα.
- Εκφράσεις δύσκολες στη κατανόηση
- Δύσκολη διαχείριση ειδικών χαρακτήρων της HTML όπως οι ©, & κ.τ.λ.



XPath

```
<td>Current <strong>UTC</strong> (or GMT/Zulu)-time used: <strong  
id="ctu">Saturday, March 5, 2011 at 21:54:12</strong><br>  
<span class="small">UTC is Coordinated Universal Time, GMT is  
Greenwich Mean Time.</span></td>
```

```
use HTML::TreeBuilder::XPath;
```

```
my $tree = HTML::TreeBuilder::XPath->new_from_content($content);  
print $tree->findnodes ('//strong[@id="ctu"]') ->shift->as_text;
```

```
#Saturday, March 5, 2011 at 21:54:12
```

Πλεονεκτήματα έναντι των κανονικών εκφράσεων:

- Λιγότερο 'εύθραυστη' προσέγγιση
- Πιο κατανοητές εκφράσεις και πιο εύκολη συντήρηση του κώδικα



CSS Selectors

```
<td>Current <strong>UTC</strong> (or GMT/Zulu)-time used: <strong  
id="ctu">Saturday, March 5, 2011 at 21:54:12</strong><br>  
<span class="small">UTC is Coordinated Universal Time, GMT is  
Greenwich Mean Time.</span></td>
```

```
use HTML::TreeBuilder::XPath;  
use HTML::Selector::XPath qw(selector_to_xpath);
```

```
my $tree = HTML::TreeBuilder::XPath->new_from_content($content);  
my $xpath = selector_to_xpath "strong#ctu";  
print $tree->findnodes($xpath)->shift->as_text;
```

```
#Saturday, March 5, 2011 at 21:54:12
```

Xpath :

`//strong[@id="ctu"]`

CSS Selector :

`strong#ctu`



open-uri

HTree / REXML

Hpricot

Nokogiri

Watir

```
require 'open-uri'
```

```
url = "http://www.google.com/search?q=ATEI+of+Thessaloniki"  
open(url) {  
  |page| page_content = page.read()  
  links = page_content.scan(/<a class=l.*?href=\"(.*)\"/).flatten  
  links.each {|link| puts link}  
}
```

-
- Υποβολή αιτήσεων μέσω της build-in βιβλιοθήκης 'open-uri'
 - Εξαγωγή δεδομένων με χρήση κανονικών εκφράσεων
 - Βλέπουμε την ιστοσελίδα ως αρχείο κειμένου



Ruby

open-uri

HTree / REXML

Hpricot

Nokogiri

Watir

```
require 'rubygems'  
require 'open-uri'  
require 'htree'  
require 'rexml/document'
```

```
open("http://www.google.com.com") do |page|  
  page_content = page.read()  
  doc = HTree(page_content).to_rexml  
  doc.root.each_element('//img') {|elem| puts elem.attribute('src').value }  
end
```

- Μετατροπή του κώδικα σε REXML (build-in XML parser της Ruby)
- Εξαγωγή δεδομένων με XPATH εκφράσεις
- Βλέπουμε την ιστοσελίδα ως DOM δέντρο και όχι σαν αρχείο κειμένου.



Ruby

open-uri

HTree / REXML

Hpricot

Nokogiri

Watir

```
require 'rubygems'  
require 'hpricot'  
require 'open-uri'
```

```
doc = Hpricot(open('http://www.google.com/search?q=ruby'))  
links = doc/"//a[@class=1]"  
links.map.each {|link| puts link.attributes['href']}
```

-
- Πιο γρήγορος και πιο εύχρηστος HTML parser από το συνδυασμό Htree/REXML
 - Υποστήριξη XPath εκφράσεων



Ruby

open-uri

HTree / REXML

Hpricot

Nokogiri

Watir

```
require 'nokogiri'  
require 'open-uri'
```

```
doc = Nokogiri::HTML(open('http://www.google.com/search?q=tenderlove'))
```

```
# css  
doc.css('h3.r a.l').each do |link|  
  puts link.content  
end
```

```
# xpath  
doc.xpath('//h3/a[@class="l"]').each do |link|  
  puts link.content  
end
```

```
# συνδιασμός και των δύο.  
doc.search('h3.r a.l', '//h3/a[@class="l"]').each do |link|  
  puts link.content  
end
```

-
- Πολύ γρήγορος HTML/XML parser
 - Υποστήριξη και XPATH και CSS εκφράσεων



Ruby

open-uri

HTree / REXML

Hpricot

Nokogiri

Watir

```
require 'rubygems'
```

```
# Καθοδήγηση του MSIE σε Windows
```

```
require 'watir'
```

```
# Καθοδήγηση του Firefox σε Windows/Mac/Linux
```

```
# require 'firewatir'
```

```
browser = Watir::Browser.new
```

```
browser.goto("http://www.example.com")
```

```
# Συμπλήρωση ενός text field
```

```
browser.text_field(:name => "text_field").set "Watir"
```

```
# Συμπλήρωση και καθαρισμός ενός radio button
```

```
browser.radio(:value => "Watir").set
```

```
browser.radio(:value => "Watir").clear
```

```
# Συμπλήρωση και καθαρισμός ενός checkbox
```

```
browser.checkbox(:value => "Ruby").set
```

```
browser.checkbox(:value => "Ruby").clear
```

```
# Κλικ σε ένα κουμπί
```

```
browser.button(:name => "submit").click
```



urllib + re

BeautifulSoup

Mechanize

```
from urllib import urlopen  
import re
```

```
p = re.compile('<a .*? href="(.*?)">(.*?)</a>')  
text = urlopen('http://www.xo.gr/').read()  
for url, name in p.findall(text):  
    print '%s (%s)' % (name, url)
```

Αποτέλεσμα:

Επικοινωνία (default_076.html)

Βοήθεια (default_077.html)

Συνήθειες Ερωτήσεις (default_078.html)

Σχόλια για "Δικός μου Χρυσός Οδηγός" (default_079.html)

...



urllib + re

BeautifulSoup

Mechanize

```
from BeautifulSoup import BeautifulSoup
import re
import urllib2
```

```
url = 'http://blogsearch.google.com/blogsearch?q=python'
response = urllib2.urlopen(url)
html = response.read()
```

```
soup = BeautifulSoup(html)
links = soup.findAll('a', id=re.compile("^p-"))
for link in links:
    print link['href']
```

Αποτέλεσμα:

```
http://www.daniweb.com/forums/thread331122.html
http://geert.vanderkelen.org/post/435/
```

...

- Ανάλυση no-valid html εγγράφων
- Αυτόματη εύρεση του encoding της σελίδας
- Εύκολη εύρεση στοιχείων της σελίδας (NextSibling, PreviousSibling, next, previous, regex, ...)



Python

urllib + re

BeautifulSoup

Mechanize

```
import mechanize
```

```
br = mechanize.Browser()
```

```
# Άνοιγμα της σελίδας  
br.open('http://gmail.com')
```

```
# Επιλογή της πρώτης φόρμας  
br.select_form(nr=0)
```

```
# Συμπλήρωση στοιχείων  
br.form['Email'] = 'yanis.potamitis'  
br.form['Passwd'] = '*****'
```

```
# Login  
br.submit()
```

Google Λογαριασμό

Όνομα Χρήστη:

Κωδικός πρόσβασης:

Παραμείνετε συνδεδεμένος

[Δεν είναι δυνατή η πρόσβαση στο λογαριασμό σας;](#)

- Υποβολή φορμών
- Αποθήκευση ιστορικού επισκέψεων.
- Συνήθως χρησιμοποιείται σε συνδυασμό με το BeautifulSoup



Simple HTML
DOM Parser

htmlSQL

loadHTMLFile +
XPath

```
$url = 'http://news.google.com/news?pz=1&cf=all&ned=el_gr  
@$dom->loadHTMLFile($url);  
$xpath = new domxpath($dom);  
  
$xNodes = $xpath->query('//div[@class="title"]');  
  
foreach ($xNodes as $xNode) {  
    $sLinktext = $xNode->firstChild->firstChild->nodeValue;  
    $sLinkurl = $xNode->firstChild->getAttribute('href');  
}
```



Simple HTML
DOM Parser

htmlSQL

loadHTMLFile +
XPath

```
SELECT href,title FROM a WHERE $class == "class_name"
```

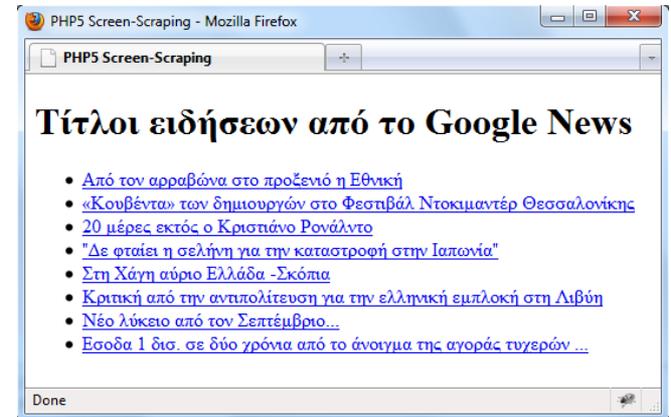
-
- Σύνταξη παρόμοια με της SQL
 - Εύρεση στοιχείων με σύντομες και κατανοητές εκφράσεις

Simple HTML
DOM Parser

htmlSQL

loadHTMLFile +
XPath

```
$url = 'http://news.google.com/news?pz=1&cf=all&ned=el_gr  
@$dom->loadHTMLFile($url);  
$xpath = new domxpath($dom);  
  
$xNodes = $xpath->query('//div[@class="title"]');  
  
foreach ($xNodes as $xNode) {  
    $sLinktext = $xNode->firstChild->firstChild->nodeValue;  
    $sLinkurl = $xNode->firstChild->getAttribute('href');  
}
```



Δημιουργία της εφαρμογής

Γιατί επιλέξαμε Python;

- Συνοπτική
- Επεκτάσιμη
- Κατανοήσιμη
- Διαδραστική
- Multiparadigm
- Multiplatform
- Διανέμεται δωρεάν

