

Lucrarea nr. 4

Clienți WEB

Mihai IVANOVICI

27 martie 2006

Una dintre cele mai utilizate tehnologii este World Wide Web-ul (WWW), iar protocolul său principal, Hypertext Transfer Protocol (HTTP) este folosit zilnic de fiecare utilizator de servicii Internet.

În această lucrare ne vom familiariza cu modulul Python `urllib2` și vom folosi acest modul pentru a descărca o pagină web, pentru a ne autentifica cu un server HTTP, a trata erorile etc.

1 Descărcarea unei pagini WEB

Descărcarea unei pagini web este frecvent o necesitate. Următorul exemplu ilustrează un client web care primește ca intrare URL-ul unei pagini web și care o afișează pe ecran.

```
#Fetch Web Page - fetch_web_page.py
```

```
import sys, urllib2
```

```
req = urllib2.Request( sys.argv[1] )  
fd = urllib2.urlopen( req )
```

```
while 1:  
    data = fd.read( 1024 )  
    if not len( data ):  
        break  
    sys.stdout.write( data )
```

Rulați acest exemplu, tastând

```
python2.4 fetch\_web\_page.py http://www.example.com/
```

Vizualizați într-un browser pagina respectivă de web.

Mai întâi se crează obiectul `urllib2.Request`, având ca parametru de intrare URL-ul paginii de web. Apoi se deschide conexiunea, apelând

`urlopen()`, care va returna un obiect de tip fișier. Acest obiect oferă informații despre pagina descărcată. Următorul exemplu ilustrează acest lucru:

```
#Show Web Page Information - show_info.py
```

```
import sys, urllib2

req = urllib2.Request( sys.argv[1] )
fd = urllib2.urlopen( req )
print "Retrieved", fd.geturl()
info = fd.info()

for key, value in info.items():
    print "%s = %s" % (key, value)
```

Rezultatul rulării acestui program poate fi următorul:

```
$ python2.4 show_info.py http://www.example.com
Retrieved http://www.example.com
last-modified = Tue, 15 Nov 2005 13:24:10 GMT
content-length = 438
etag = "63ffd-1b6-80bfd280"
date = Tue, 14 Mar 2006 17:11:27 GMT
accept-ranges = bytes
content-type = text/html; charset=UTF-8
connection = close
server = Apache/2.0.54 (Fedora)
```

2 Autentificarea

Unele servere WEB nu permit accesul unui client dacă acesta nu se autentifică. Cea mai simplă și utilizată metodă de autentificare este aceea în care clientul trimite serverului un nume de utilizator (username) și o parolă (password).

De regulă, autentificarea via HTTP presupune apariția în browser a unei ferestre pop-up, prin care se cere clientului introducerea numelui de utilizator și a parolei.

De multe ori autentificarea via HTTP este combinată cu comunicația criptată folosind SSL (HTTPS), pentru a asigura securitatea datelor trimise pentru autentificare, cum ar fi parolele. Modulul Python `urllib2` oferă suport pentru SSL, ceea ce înseamnă că URL-urile `https` sunt automat tratate în același fel ca cele `http` simple.

Dacă încercați să accesați un URL care necesită autentificare folosind programul exemplificat mai devreme, se va genera eroarea HTTP nr. 401 "Authorisation Required". Verificați acest lucru pentru următorul URL: <http://www.unicode.org/mail-arch/unicode-ml/>. Rezultatul va arăta similar cu:

```
$ python2.4 show_info.py http://www.unicode.org/mail-arch/unicode-ml/
Traceback (most recent call last):
  File "show_info.py", line 7, in ?
    fd = urllib2.urlopen( req )
  File "/usr/lib/python2.2/urllib2.py", line 138, in urlopen
    return _opener.open(url, data)
  File "/usr/lib/python2.2/urllib2.py", line 328, in open
    '_open', req)
  File "/usr/lib/python2.2/urllib2.py", line 307, in _call_chain
    result = func(*args)
  File "/usr/lib/python2.2/urllib2.py", line 824, in http_open
    return self.do_open(httplib.HTTP, req)
  File "/usr/lib/python2.2/urllib2.py", line 818, in do_open
    return self.parent.error('http', req, fp, code, msg, hdrs)
  File "/usr/lib/python2.2/urllib2.py", line 354, in error
    return self._call_chain(*args)
  File "/usr/lib/python2.2/urllib2.py", line 307, in _call_chain
    result = func(*args)
  File "/usr/lib/python2.2/urllib2.py", line 406, in http_error_default
    raise HTTPError(req.get_full_url(), code, msg, hdrs, fp)
urllib2.HTTPError: HTTP Error 401: Authorization Required
```

Exemplul următor tratează și cazul în care autentificarea este cerută de către server:

```
#Show Web Page Information With Authentication
#show_info_auth.py

import sys, urllib2, getpass

class TerminalPassword( urllib2.HTTPPasswordMgr ):
    def find_user_password( self, realm, authuri ):
        retval = urllib2.HTTPPasswordMgr.find_user_password( self, realm, authuri )
        if retval[0] == None and retval[1] == None:
            #Didn't find it in stored values; ask the user
            sys.stdout.write( "Login required for %s at %s\n" % (realm, authuri))
            sys.stdout.write( "Username: " )
            username = sys.stdin.readline().rstrip()
            password = getpass.getpass().rstrip()
            return (username, password)
        else:
            return retval

req = urllib2.Request( sys.argv[1] )
opener = urllib2.build_opener( urllib2.HTTPBasicAuthHandler(TerminalPassword()))
fd = opener.open( req )
print "Retrieved", fd.geturl()
```

```

info = fd.info()

for key, value in info.items():
    print "%s = %s" % (key, value)

```

Acest exemplu conține în plus față de precedentul următoarele:

- Definiția clasei `TerminalPassword` ca o extensie a clasei `urllib2.HTTPPasswordMgr`. Aceasta permite programului interogarea utilizatorului în vederea aflării numelui și a parolei;
- Apelul funcției `build_opener()`. Această funcție permite specificarea “handler-ului” sau a metodei care va oferi suport HTTP, adică `HTTPBasicAuthHandler` în exemplul de mai sus.

Odată ce comunicația este inițiată, `HTTPBasicAuthHandler` va apela funcția corespunzătoare din `TerminalPassword`, atunci când este nevoie de autentificarea clientului.

Rulați acest nou exemplu pentru URL-ul de mai sus, specificând ca nume de utilizator “unicode-ml”, iar ca parolă “unicode”. Rezultatul rulării arată în felul următor:

```

$ python2.4 show_info_auth.py http://www.unicode.org/mail-arch/unicode-ml/
Login required for Unicode-MailList-Archives at www.unicode.org
Username: unicode-ml
Password:
Retrieved http://www.unicode.org/mail-arch/unicode-ml/
date = Tue, 14 Mar 2006 18:48:01 GMT
connection = close
content-type = text/html
server = Apache

```

3 Trimiterea de date prin forme

Scripturile CGI sau alte programe interactive care rulează pe serverele web pot primi date de la clienți, de cele mai multe ori sub forma unor “forme”. Există două metode pentru a trimite forme: GET și POST. Metoda este de obicei specificată de parametrul `method` în tag-ul HTML `<form>`.

3.1 Trimiterea de date folosind GET

Metoda de trimitere de date folosind GET presupune codarea formei în URL. La sfârșitul căii către pagina ce trebuie descărcată se adaugă un semn de întrebare (?), urmată de elementele formei. Fiecare element al formei este delimitat de ampersand (&). Deoarece toate datele formei sunt incluse în URL, metoda GET nu este folosită atunci când formele au dimensiuni foarte mari.

```
#Submit GET Data - submit_GET.py

import sys, urllib2, urllib

def addGETdata( url, data ):
    return url + '?' + urllib.urlencode( data )

city = sys.argv[1]
url = addGETdata( 'http://vremea.rol.ro/prognozaoras.php', [('0', city)])
print "Using URL: ", url
req = urllib2.Request( url )
fd = urllib2.urlopen( req )

while 1:
    data = fd.read( 1024 )
    if not len( data ):
        break
    sys.stdout.write( data )
```

Al doilea parametru al funcției `addGETdata` este o listă de tuplu-uri de forma (key, value). Elementele care nu au “key”, vor conține cuvântul cheie “None”.

Rulați exemplul de mai sus pentru câteva nume de orașe din România. Observați cum se construiește URL-ul ce conține forma trimisă prin metoda GET.

```
$ python2.4 submit_GET.py Brasov
Using URL: http://vremea.rol.ro/prognozaoras.php?0=Brasov
<html>
<head>
<title>Vremea in Brasov, meteo, vremea.ro, prognoza meteo, Brasov</title>
...
```

3.2 Trimiterea de date folosind POST

Trimiterea de date (forme) folosind metoda POST diferă puțin de metoda GET: datele nu mai sunt incluse în URL, ci sunt trimise ca parte a cererii de conexiune.

Nu este obligatoriu ca serverele de web să accepte ambele metode și de regulă acceptă numai una din metode. Este datoria clientului să implementeze ambele moduri de a trimite forme către server.

Observați în următorul exemplu cum datele sunt trimise către server folosind metoda POST.

```
#Submit POST Data - submit_POST.py
```

```

import sys, urllib2, urllib

city = sys.argv[1]
url = 'http://vremea.rol.ro/prognozaoras.php'
data = urllib.urlencode( [('0', city)] )
req = urllib2.Request( url )
fd = urllib2.urlopen( req, data )

while 1:
    data = fd.read( 1024 )
    if not len( data ):
        break
    sys.stdout.write( data )

```

4 Tratarea erorilor

4.1 Erori de conexiune

Procesul de stabilire a conexiunii cu serverul web este locul în care pot apărea cel mai frecvent erori: URL-ul poate conține o eroare, URL-ul conține un protocol care nu este suportat, numele serverului poate să nu existe, serverul nu este accesibil sau acesta returnează o eroare, ca de exemplu 404, "File Not Found".

```

#Get Web Page Information with Simple Error Handling
# - error_basic.py

```

```

import sys, urllib2

req = urllib2.Request( sys.argv[1] )

try:
    fd = urllib2.urlopen( req )
except urllib2.URLError, e:
    print "Error retrieving data: ", e
    sys.exit( 1 )

print "Retrieved", fd.geturl()
info = fd.info()
for key, value in info.items():
    print "%s = %s" % (key, value)

```

În general erorile HTTP sunt însoțite de un document care descrie excepția care a generat respectiva eroare. Acest document generat de server este un

obiect de tip fișier și deci poate fi tratat ca atare. Uneori erorile nu sunt de tipul `HTTPError`, prin urmare clientul trebuie să fie capabil să trateze și erorile de tipul `URLError`. Un exemplu ce tratează ambele tipuri de erori este prezentat în continuare:

```
#Obtain Web Page Information with Error Document Handling
#error_doc.py
import sys, urllib2

req = urllib2.Request( sys.argv[1] )

try:
    fd = urllib2.urlopen( req )
except urllib2.HTTPError, e:
    print "Error retrieving data: ", e
    print "Server error document follows:\n"
    print e.read()
    sys.exit( 1 )
except urllib2.URLError, e:
    print "Error retrieving data: ", e
    sys.exit( 2 )

print "Retrieved", fd.geturl()
info = fd.info()
for key, value in info.items():
    print "%s = %s" % (key, value)
```

Rulați acest exemplu pentru un URL inexistent, cum ar fi:
<http://www.google.com/hello.html>.

4.2 Erori de date

Două feluri de erori pot apărea în timpul citirii datelor de la server: (i) erori de comunicație care generează o excepție de tipul `socket.error` în timpul apelului `read()` sau (ii) documentul poate fi trunchiat (chiar în cazul în care nu a fost nici o eroare de comunicație).

Trunchierea documentului înseamnă primirea unui document mai scurt decât cel care se dorea a fi transferat. Modul în care se detectează acest lucru este prin verificarea header-ului `Content-Length` din răspunsul serverului. Dacă acest header este prezent, se poate compara volumul de date primite de la server cu valoarea indicată în header.

Exemplul următor tratează atât erorile de socket, cât și cele cauzate de documente trunchiate:

```
#Obtain Web Page Information with Full Error Handling
```

```

#error_all.py
import sys, urllib2

req = urllib2.Request( sys.argv[1] )

try:
    fd = urllib2.urlopen( req )
except urllib2.HTTPError, e:
    print "Error retrieving data: ", e
    print "Server error document follows:\n"
    print e.read()
    sys.exit( 1 )
except urllib2.URLError, e:
    print "Error retrieving data: ", e
    sys.exit( 2 )

print "Retrieved", fd.geturl()

bytesread = 0

while 1:
    try:
        data = fd.read( 1024 )
    except socket.error, e:
        print "Error reading data: ", e
        sys.exit( 3 )

    if not len( data ):
        break
    bytesread += len( data )
    sys.stdout.write( data )

if fd.info().has_key( 'Content-Length' ) and \
long( fd.info()['Content-Length'] ) != long( bytesread ):
    print "Expected a document of size %d, but read %d bytes" % \
        (long(fd.info()['Content-Length']), bytesread)
    sys.exit( 4 )

```