# Ruby. Praktyczne skrypty, które rozwiążą trudne problemy

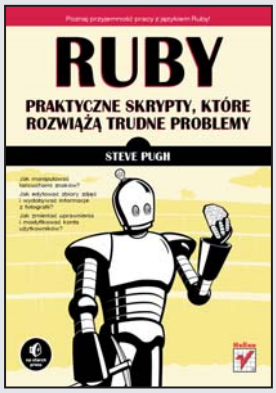


Autor: Steve Pugh
Tłumaczenie: Tomasz Walczak, Marek Kowalcze
ISBN: 978-83-246-2254-2
Tytuł oryginału: Wicked Cool Ruby Scripts: Useful Scripts that Solve Difficult Problems
Format: 170x230, stron: 232

**Poznaj przyjemność pracy z językiem Ruby!**

- Jak manipulować łańcuchami znaków?
- Jak edytować zbiory zdjęć i wydobywać informacje z fotografii?
- Jak zmieniać uprawnienia i modyfikować konta użytkowników?

Ruby to obiektowy język programowania, przeznaczony do użytku ogólnego, udostępniający bogaty zestaw narzędzi służących do pisania skryptów. Jedną z największych zalet tego języka jest fakt, że wyjątkowo dobrze nadaje się on do tworzenia efektywnych programów proceduralnych. Dzięki tej książce nauczysz się wykorzystywać niezwykłe właściwości języka Ruby, aby zautomatyzować większość zadań i wykonywać swoją pracę bez trudu i z przyjemnością.

Książka „Ruby. Praktyczne skrypty, które rozwiążą trudne problemy" zawiera 58 niezwykle przydatnych skryptów, które pozwalają szybko rozwiązać często spotykane problemy, między innymi z administrowaniem systemem, manipulowaniem rysunkami i zarządzaniem witryną. Przy każdym skrypcie znajdziesz kod, omówienie jego działania i wskazówki opisujące, jak dostosować rozwiązanie do własnych potrzeb. Z podręcznika dowiesz się, jak posługiwać się skryptami do automatyzacji zadań (takich jak archiwizowanie czy wypakowywanie plików), a także na czym polega szyfrowanie plików oraz przetwarzanie wiadomości RSS. Nauczysz się tworzyć zaawansowane roboty sieciowe, skrypty z obszaru zabezpieczeń oraz kompletne biblioteki i aplikacje.

- Skrypty do zarządzania witrynami
- Pisanie skryptów sieciowych
- Administrowanie systemami Linux i Unix
- Walidacja rozwiązań symbolicznych
- Narzędzia do manipulowania zdjęciami
- Tworzenie galerii fotografii
- Narzędzia do przetwarzania łańcuchów znaków
- Serwery i wydobywanie danych
- Argumenty i dokumentacja
- Algorytmy sortowania

**Skorzystaj z praktycznych skryptów w języku Ruby i oszczędzaj czas, aby pracować szybko i wydajnie**



Helion SA
ul. Kościuszki 1c
44-100 Gliwice
tel. 032 230 98 63
e-mail: helion@helion.pl

# Spis treści

# 7

# Serwery i wydobywanie danych

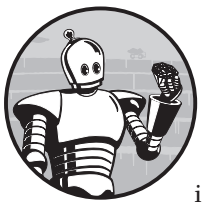

MOCNĄ STRONĄ JĘZYKA RUBY JEST MOŻLIWOŚĆ UŻYCIA GO DO ZAUTOMATYZOWANIA INTERAKCJI Z ZASOBAMI SIECI WWW. TEN ROZDZIAŁ ZAWIERA KRÓTKIE OMÓWIENIE PROCESU PRZETWARZANIA STRON WWW I KOŃCZY SIĘ ZBIOREM DZIAŁających po stronie klienta oraz serwera skryptów, które służą do bezpiecznego przekazywania i uruchamiania poleceń. Interakcja z siecią WWW i wydobywanie z niej informacji (czyli tak zwany *data mining*) są ważne z uwagi na bogactwo dostępnych w niej materiałów. Zamiast wydobywać złoto, użytkownicy szukają różnych sposobów na pobranie ważnych danych i przekształcenie ich na znaczące informacje.

## 42. Definicje

**define.rb** Ten skrypt kieruje zapytanie do witryny *http://www.dictionary.com/* i pobiera pierwszą definicję słowa wskazanego przez użytkownika. Podobnie jak w przypadku innych programów komunikujących się z siecią WWW istnieje ryzyko, że skrypt przestanie działać, jeśli projektanci witryny wprowadzą w niej zmiany.

Zadanie programu polega na wydobywaniu określonych danych. Użyłem witryny Dictionary.com tylko jako środka do zaprezentowania tego mechanizmu, jednak omawiany przykład to pomysłowe rozwiązanie.

### Kod

```
❶ require "open-uri"

unless ARGV[0]
    puts "Musisz podać definiowane słowo."
    puts "Sposób użycia: ruby define.rb <definiowane słowo>"
    exit
end

❷ word = ARGV[0].strip

❸ url = "http://dictionary.reference.com/browse/#{word}"

begin
❹     open(url) do |source|
      source.each_line do |x|
❺         if x =~ /No results found/
          puts "\nDefinicji nie znaleziono - sprawdź pisownię."
          exit
      end
❻         if x =~ /(1\.)<\/td> <td>(.*)<\/td/
          puts "\n#{$1} #{$2}"
          exit
      end
end
❼     puts "Niestety, nie można znaleźć definicji."
end
rescue => e
    puts "Wystąpił błąd – spróbuj ponownie."
    puts e
end
```

### Uruchamianie kodu

Uruchom skrypt przez wpisanie następującej instrukcji:

```
ruby define.rb definiowane_słowo
```

Chciałem znaleźć definicję słowa *Ruby*. Niestety, pierwsze zwrócone objaśnienie nie brzmiało *najbardziej odjazdowy języka programowania*.

### *Dane wyjściowe*

Skrypt wyświetla definicję podanego słowa. Jeśli nie można jej znaleźć, program prosi użytkownika o sprawdzenie pisowni. Możliwe, że podany wyraz w ogóle nie istnieje.

```
1.a red variety of corundum, used as a gem.
```

### *Jak działa ten skrypt?*

Ponownie wykorzystałem tu fantastyczną bibliotekę `open-uri` ❶. Do komunikacji skryptu z siecią WWW można używać wielu przydatnych narzędzi tego typu. Ja lubię `open-uri`, ponieważ ukrywa więcej szczegółów procesu łączenia się z siecią niż inne biblioteki. Po dołączeniu biblioteki program sprawdza błędy. Mam nadzieję, że przyzwyczaiłeś się już do używanego bloku kodu. W pierwszej zmiennej (`word`) skrypt zapisuje słowo, którego definicję użytkownik chce znaleźć ❷. Następnie program przypisuje do zmiennej `url` zapisany na stałe adres URL serwisu Dictionary.com z dołączonym wyrazem podanym jako argument ❸. Budowa używanej witryny sprawia, że dołączenie słowa do adresu powoduje automatyczne zwrócenie definicji.

W dalszej części skryptu znajduje się instrukcja `begin/rescue`, potrzebna z uwagi na zmienną naturę żądań sieciowych. Odpowiedzi na żądania HTTP często zawierają komunikaty o błędach. Ich właściwa obsługa to klucz do prawidłowego działania tego skryptu. Po dodaniu siatki zabezpieczającej w postaci bloku `begin/rescue` można wysłać do serwisu Dictionary.com prośbę o podanie definicji. Kiedy korzystasz z biblioteki `open-uri`, wystarczy, że wpiszesz instrukcję `open()` z adresem URL, a skrypt zwróci odpowiednią stronę WWW ❹. Pobieranie stron za pomocą tej metody jest tak proste, że zawsze kiedy jej używam, na mojej twarzy gości uśmiech.

Po metodzie `open` następuje blok, który przetwarza kod źródłowy zwrócony przez serwer sieciowy. Ponieważ chcemy pobrać specyficzny wiersz (definicję słowa), w następnym bloku skrypt dzieli kod źródłowy na wiersze. Jeśli serwis Dictionary.com nie znajdzie danego słowa, wyświetli komunikat *No results found*. Gdy skrypt w czasie analizowania kodu źródłowego wykryje podany wyraz, ale już nie jego definicję, wyświetli wskazówkę w postaci prośby o sprawdzenie pisowni słowa, a następnie zakończy działanie ❺. Jeżeli jednak definicja jest dostępna, skrypt stara się wyodrębnić ją z kodu źródłowego. Do pobrania jej tekstu służy wyrażenie regularne.

Ważną częścią użytego w skrypcie wyrażenia regularnego jest cyfra `1`. Witryna Dictionary.com używa jej jako wskaźnika pierwszej definicji, którą program ma pobrać. Użycie w wyrażeniu regularnym nawiasów umożliwia skryptowi pogrupowanie określonych fragmentów dowolnego wiersza, które pasują do wyrażenia ❻. Te grupy są zapisywane w zmiennych o nazwach od `$1` do `$n`. Wiersz pod wyrażeniem regularnym wyświetla definicję. Jeśli program nie znajdzie w kodzie źródłowym ani definicji, ani tekstu *No results found*, zwróci inny komunikat, który

informuje użytkownika o tym, że nie można znaleźć wyjaśnienia słowa ❼. Jeśli w czasie przetwarzania definicji pojawią się problemy, program uruchomi blok `rescue` i poinformuje, jaki błąd wystąpił.

### Modyfikowanie skryptu

Jednym ze sposobów na zmodyfikowanie skryptu jest dodanie obsługi pośrednika między użytkownikiem a żądaniem do serwera sieciowego. Jeśli korzystasz z takiego pośrednika, musisz zastosować to rozwiązanie. Jeżeli interesuje Cię ruch w sieci generowany przez skrypt w języku Ruby, pośrednik pomoże Ci uzyskać dodatkowe informacje. Aby dowiedzieć się, jak je uzyskać, zajrzyj do dokumentacji biblioteki `open-uri`. Potrzebna składnia wygląda następująco: `open(url, :proxy => "http://127.0.0.1:8080")`. Zwykle nie korzystam z pośrednika przy przeglądaniu sieci WWW, jednak jeśli w trakcie tworzenia stron wykryję błędy, często pomocne jest przyjrzenie się ruchowi w sieci.

Do diagnozowania problemów używam bezpłatnego sieciowego pośrednika Paros (*http://www.parosproxy.org/*). Narzędzie to należy zainstalować lokalnie na własnej maszynie, a następnie można obserwować zgłaszane żądania sieciowe i odbierane odpowiedzi. Dzięki wykorzystaniu przy programowaniu narzędzia Paros zaoszczędziłem sobie wielu godzin diagnozowania. Jestem bardzo przywiązany do tego pośrednika, jednak istnieje też wiele innych podobnych programów, dlatego warto poszukać czegoś dla siebie.

# 43. Automatyczne wysyłanie SMS-ów

**sms.rb** Ten skrypt wysyła wiadomość SMS pod podany numer telefonu komórkowego. Ostrzegam przed nadużywaniem tej funkcji, jednak musisz wypróbować ten program[1]. Skrypt ma automatyzować korzystanie z witryny, która służy do wysyłania wiadomości SMS. Zamiast pobierać statyczną zawartość strony, skrypt ten automatyzuje wypełnianie i przesyłanie formularza.

### Kod

```
require 'win32ole'

❶ ie = WIN32OLE.new('InternetExplorer.Application')
❷ ie.navigate("http://toolbar.google.com/send/sms/index.php")

ie.visible = true
❸ sleep 1 until ie.readyState() == 4

❹ ie.document.all["mobile_user_id"].value ="5712013623"
```

[1] Serwis użyty w tym skrypcie zakończył działalność, jednak za pomocą tej samej techniki możesz przesyłać wiadomości w innych bramkach SMS — *przyp. tłum.*

```
ie.document.all["carrier"].value ="TMOBILE"
ie.document.all["subject"].value ="***Ruby rządzi***"
❺ ie.document.all.tags("textarea").each do |i|
    i.value = "Dzięki za dobrą robotę, Matz!"
end

❻ ie.document.all.send_button.click
```

### Uruchamianie kodu

```
Aby uruchomić ten skrypt, wpisz następujące polecenie:
```

```
ruby sms.rb
```

### Dane wyjściowe

Ten skrypt nie generuje żadnych danych, jednak jeśli udanie zakończy działanie, telefon o podanym numerze powiadomi Cię o odebraniu wiadomości. W przykładzie użyłem fikcyjnych danych, jednak możesz je zmienić, aby wypróbować program.

### Jak działa ten skrypt?

Jeśli korzystasz z komputera z systemem Windows i nigdy nie używałeś biblioteki `win32ole`, powinieneś poświęcić trochę czasu na jej opanowanie, ponieważ automatyzowanie wykonywania zadań w tym systemie jest ciekawe i daje dużo satysfakcji. Możesz nie tylko manipulować przeglądarką Internet Explorer, co ilustruje ten skrypt, ale też dowolnym produktem z pakietu Microsoft Office i innymi aplikacjami systemu Windows.

**UWAGA** *Dostępnych jest też kilka bibliotek przeznaczonych do automatyzacji witryn. Narzędzia te są niezwykle przydatne do testów regresji i jakości aplikacji sieciowych. Jedną z popularnych bibliotek tego typu jest Watir. Szczegółowe informacje na jej temat znajdziesz na stronie* http://wtr.rubyforge.org/.

Skrypt tworzy nowy obiekt typu `win32ole` na podstawie argumentu w postaci uchwytu przeglądarki IE ❶. Uchwyt ten informuje bibliotekę `win32ole`, którą aplikację ma kontrolować. Przy użyciu wbudowanej w przeglądarkę IE metody `navigate` skrypt przechodzi pod określony adres URL — *http://toolbar.google.com/send/sms/index.php* ❷. Następny wiersz ustawia atrybut okna przeglądarki. Jeśli nie chcesz widzieć, jak skrypt wykonuje swe zadania, możesz użyć w tym wierszu wartości `false`, a okno przeglądarki będzie działać w tle. Wtedy jego obecność będziesz mógł wykryć tylko na liście zadań. Ponieważ lubię widzieć działanie programu, ustawiłem wspomniany atrybut na `true`. Aplikacja Internet Explorer pojawi się i zniknie w krótkim czasie, dlatego bacznie przyglądaj się ekranowi.

Następnie skrypt uruchamia pętlę, która warunkowo wczytuje stronę. Jak pewnie wiesz, strony witryn nie pojawiają się natychmiast. Aby skrypt nie przesłał informacji przedwcześnie, należy „uśpić" program na sekundę, a następnie sprawdzić, czy kod `readyState` ma właściwą wartość (4) ❸. Przedwczesne działania nigdy nie są korzystne, a w tym przypadku spowodują, że skrypt przestanie działać. Po zakończeniu wczytywania dokumentu przez przeglądarkę IE skrypt może wypełnić odpowiednie pola.

Program wykrywa odpowiednie pola na podstawie nazw atrybutów. Jeśli zajrzysz do kodu źródłowego witryny, znajdziesz obiekty o nazwach `mobile_user_id`, `carrier`, `subject` i tak dalej. Te informacje służą do określenia, gdzie skrypt ma zapisać poszczególne dane wejściowe ❹. Większość kodu HTML z omawianej witryny jest zgodna ze standardami, jednak z nieznanych przyczyn wartość atrybutu `name` obszaru tekstowego nie znajduje się w cudzysłowach. Oznacza to, że nie można użyć wcześniej zastosowanej metody, aby uzyskać dostęp do tego obszaru. Jednak ponieważ w kodzie źródłowym znajduje się tylko jeden obszar tekstowy, wystarczy go znaleźć i zapisać w nim odpowiednie dane. Nie jest to wymyślna technika, ale nieco różni się od zastosowanego wcześniej podejścia ❺.

Po dodaniu informacji trzeba tylko wirtualnie kliknąć przycisk do wysyłania formularza. Programiści firmy Google prawidłowo nazywają przyciski, dlatego wystarczy pobrać odpowiednią nazwę i użyć jej w metodzie `click` ❻. I to już wszystko — język Ruby jest fantastyczny!

# 44. Wydobywanie odnośników

**linkScrape.rb**

Wydobywanie odnośników ze stron WWW ma wiele zastosowań. Można to zrobić — podobnie jak w przypadku innych zadań — na wiele sposobów. W rozdziale 2. zobaczyłeś skrypt do sprawdzania poprawności odnośników w witrynie. Z uwagi na konieczność walidacji odsyłaczy program ten wymagał większej liczby wierszy kodu niż skrypt, który musi tylko wydobyć wszystkie odnośniki. Nie zamierzam tworzyć tu robota sieciowego, jednak opiszę kilka jego podstawowych komponentów. Pierwszy z nich to mechanizm wydobywania odnośników.

## *Kod*

```
❶ require 'mechanize'

unless ARGV[0]
    puts "Musisz podać adres witryny."
    puts "Sposób użycia: ruby linkScrape.rb <przetwarzany adres URL>"
    exit
end

❷ agent = WWW::Mechanize.new
agent.set_proxy('localhost',8080)
```

```
begin
❸    page = agent.get(ARGV[0].strip)

    page.links.each do |l|
        if l.href.split("")[0] =='/'
❹           puts "#{ARGV[0]}#{l.href}"
        else
            puts l.href
        end
    end
rescue => e
    puts "Wystąpił błąd."
    puts e
    retry
end
```

### *Uruchamianie kodu*

W celu uruchomienia skryptu wpisz następujące polecenie:

```
ruby linkScrape.rb http://przetwarzany_adres_url.com/
```

### *Dane wyjściowe*

Skrypt wyświetla listę wszystkich odnośników znalezionych na stronie o podanym adresie URL. Ja wydobyłem odsyłacze ze strony *http://www.nostarch.com/main_menu.htm*.

*index.htm*
*catalog.htm*
*wheretobuy.htm*
*about.htm*
*jobs.htm*
*media.htm*
*http://www.nostarch.com/blog/*
*http://ww6.aitsafe.com/cf/review.cfm?userid=8948354*
*abs_bsd2.htm*
*openbsd.htm*
*freebsdserver.htm*
*debian.htm*
*howlinuxworks.htm*
*appliance.htm*
*lcbk2.htm*
*lme.htm*
*nongeeks.htm*
*lps.htm*
*interactive.htm*
*gimp.htm*
*inkscape.htm*
*js2.htm*
*eblender.htm*
*oophp.htm*
*wpdr.htm*
*webbots.htm*
*google.htm*
*growingsoftware.htm*
*rootkits.htm*
*hacking2.htm*
*voip.htm*
*firewalls.htm*
*securityvisualization.htm*
*silence.htm*
*stcb4.htm*
*scsi2.htm cisco.htm*
*cablemodem.htm*

*mug.htm*
*ubuntu_3.htm*
*imap.htm*
*pf.htm*
*postfix.htm*
*webmin.htm*
*endingspam.htm*
*cluster.htm*
*nagios.htm*
*nagios_2e.htm*
*pgp.htm*
*packet.htm*
*tcpip.htm*
*assembly.htm*
*debugging.htm*
*qt4.htm*
*vb2005.htm*
*vsdotnet.htm*
*codecraft.htm*
*hownotc.htm*
*idapro.htm*
*mugperl.htm*
*gnome.htm*
*plg.htm*
*ruby.htm*
*vbexpress.htm*
*wcj.htm*
*wcps.htm*
*wcphp.htm*
*wcruby.htm*
*wcss.htm*
*greatcode.htm*
*greatcode2.htm*
*wpc.htm*
*xbox.htm*
*insidemachine.htm*
*nero7.htm*
*wireless.htm*
*creative.htm*
*ebaypg.htm*
*ebapsg.htm*
*geekgoddess.htm*
*wikipedia.htm*
*indtb.htm*
*sayno.htm*
*networkknowhow.htm*
*sharing.htm*
*apple2.htm*
*newmac.htm*
*cult_mac.htm*
*ipod.htm*
*art_of_raw.htm*
*firstlego.htm*
*flego.htm*
*legotrains.htm*
*sato.htm*
*nxt.htm*
*nxtonekit.htm*
*zoo.htm*
*legobuilder.htm*
*nxtig.htm*
*vlego.htm*
*mg_databases.htm*
*mg_statistics.htm*
*eli.htm*
*index.htm*

### *Jak działa ten skrypt?*

Porównaj kod tego programu ze skryptem 10. — „Weryfikator odnośników do stron w sieci". Widać dużą różnicę, prawda? Zawsze warto przemyśleć problem i starać się rozwiązać go w najprostszy możliwy sposób. Niektóre z najbardziej eleganckich rozwiązań w ogóle nie są skomplikowane. Przedstawiony skrypt jedynie wydobywa odnośniki ze strony bez sprawdzania ich poprawności i wykonywania innych zadań. Biblioteka `mechanize` to następne narzędzie często używane do interakcji z internetem ❶. Skrypt po standardowej instrukcji do obsługi błędów tworzy nowy obiekt `agent` typu `mechanize` ❷. Aby dostosować ten obiekt do potrzeb programisty, program ustawia atrybut pośrednika na lokalny program Paros,

którego używam. Jeśli nie chcesz korzystać z narzędzia tego rodzaju, usuń ten wiersz kodu. Następnie skrypt używa metody `get` obiektu `agent` do pobrania zawartości strony ❸. Ciekawą cechą biblioteki `mechanize` jest automatyczne kategoryzowanie pobranych informacji. Wyszukiwanie specyficznych elementów strony za pomocą tej biblioteki znacznie ułatwia życie programistom języka Ruby.

W zmiennej `page` znajduje się tablica `links`. Dzięki bibliotece `mechanize` odnośniki są już przetworzone. Podobnie jak przy korzystaniu z każdej innej tablicy można użyć metody `each` do przejścia po wszystkich elementach tablicy `links`. Pamiętaj, że elementy `link` zawierają nie tylko adres URL każdego odnośnika, ale też inne atrybuty zdefiniowane w kodzie źródłowym. Tu potrzebny jest tylko atrybut `href`, aby skrypt mógł wyświetlić go w konsoli ❹. Jeśli chcesz wydobyć informacje z dużej witryny, powinieneś zapisać dane w pliku, ale wybór podejścia należy do Ciebie. Po wyświetleniu odnośników skrypt kończy działanie.

### *Modyfikowanie skryptu*

Istnieje kilka innych ciekawych narzędzi sieciowych, które przetwarzają strony w podobny sposób. Są to na przykład Hpricot (*http://wiki.github.com/why/hpricot/*) i Rubyful Soup (*http://www.crummy.com/software/RubyfulSoup/*). Wypróbuj je, aby znaleźć narzędzie dostosowane do własnych potrzeb.

# 45. Wydobywanie rysunków

**imageScrape.rb** Ten skrypt wydobywa każdy rysunek ze strony o adresie URL podanym przez użytkownika. Pobierane pliki graficzne obejmują obrazki znajdujące się na serwerze danej strony, a także rysunki dołączane z innych serwerów sieciowych.

### *Kod*

```
require "open-uri"
require "pathname"

unless ARGV[0]
    puts "Musisz podać adres URL, aby wydobyć rysunki."
    puts "Sposób użycia: ruby imageScrape.rb <przetwarzany adres URL>"
    exit
end

url = ARGV[0].strip
begin
❶   open(url, "User-Agent" => "Mozilla/4.0 (compatible; MSIE 5.5; Windows
    ↪98)")
do |source|
        source.each_line do |x|
❷           if x =~ /<img src="(.+.[jpeg|gif])"\s+/
                name = $1.split('"').first
```

```
❸                 name = url + name if Pathname.new(name).absolute?
❹                 copy = name.split('/').last

❺                 File.open(copy, 'wb') do |f|
                      f.write(open(name).read)
                  end
              end
          end
      end
rescue => e
      puts "Wystąpił błąd – spróbuj ponownie."
      puts e
```

### *Uruchamianie kodu*

Uruchom skrypt przez wpisanie poniższej instrukcji:

```
ruby imageScrape.rb http://przetwarzany_adres_url.com/
```

### *Dane wyjściowe*

Ten skrypt pobiera wszystkie rysunki znalezione na stronie o podanym adresie URL. Ja włączyłem przetwarzanie strony *http://www.ruby-lang.org/* i pobrałem dwa obrazki: *logo.gif* (logo języka Ruby) i *download.gif* (rysunek-odnośnik, który pozwala pobrać język Ruby).

### *Jak działa ten skrypt?*

Pierwszy etap wydobywania rysunków polega na pobraniu całej strony. Przy użyciu metody `open` biblioteki `open-uri` można wygodnie zapisać kod źródłowy strony w zmiennej `source` ❶. Jak sobie pewnie przypominasz z czasów pisania kodu w języku HTML, rysunki w dokumentach sieciowych są zagnieżdżane za pomocą znaczników `<img src=plik.jpg>`. W tym skrypcie użyłem wyrażenia regularnego, które analizuje każdy wiersz kodu źródłowego i wyszukuje podobne znaczniki ❷. Dzięki danym zwróconym przez wyrażenie regularne program może określić lokalizację znalezionych obrazków.

Po ustaleniu lokalizacji rysunku trzeba określić, czy obrazek pochodzi z zewnętrznej, czy z przetwarzanej witryny. W kodzie HTML rysunki z lokalnego serwera sieciowego są zwykle poprzedzone ukośnikiem (ich adres ma postać *ścieżki bezwzględnej*). W kodzie ścieżkę do obrazka zawiera zmienna `name`. Jeśli jest to ścieżka bezwzględna, skrypt dołącza ją do adresu URL strony, aby utworzyć kompletny adres rysunku. Sprawdzanie rodzaju ścieżki odbywa się przy użyciu metody `absolute?` i ma miejsce przy tworzeniu nowego obiektu typu `Pathname` ❸. Choć ścieżka do rysunku może się zmienić, jego nazwa jest stała i znajduje się w zmiennej `copy` ❹.

Po utworzeniu poprawnego adresu rysunku skrypt wykorzystuje obsługę plików wirtualnych, którą zapewnia biblioteka `open-uri`, w celu wczytania obrazka

i zapisania go w pliku (jego nazwę zawiera zmienna `copy`) ❺. Ten proces należy powtórzyć dla każdego rysunku znalezionego w dokumencie. Efekt tych operacji skrypt zapisuje w katalogu, w którym został uruchomiony.

### *Modyfikowanie skryptu*

Możesz użyć gotowego parsera kodu HTML, takiego jak `mechanize`, Hpricot lub Rubyful Soup. Te narzędzia działają jeszcze dokładniej niż wyrażenie regularne zastosowane w skrypcie. Ponadto możesz zapisać rysunki w takiej samej strukturze katalogów, w jakiej znajdowały się na serwerze sieciowym. Istnieje wiele różnych możliwości, a ten skrypt to dobry punkt wyjścia.

# 46. Narzędzie do wydobywania danych ze stron WWW

**scrape.rb** Scraping w swej najprostszej postaci polega na wydobywaniu danych z innych witryn za pomocą standardowych zapytań HTTP. Przeznaczony do tego skrypt to wzbogacona wersja poprzednich programów. Program ten łączy omówione wcześniej techniki i udostępnia kilka dodatkowych funkcji. Jest to uniwersalne narzędzie do prostego pobierania danych ze stron. Nie jest to bot, ponieważ wszystkie działania skryptu wymagają interakcji z użytkownikiem, jednak po wprowadzeniu kilku drobnych usprawnień program ten można w pełni zautomatyzować.

### *Kod*

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

unless ARGV[0] and ARGV[1]
    puts "Musisz określić operację i adres URL."
    puts "Sposób użycia: scrape.rb [strona|rysunki|linki] <przetwarzany
    ↪adres URL>"
    exit
end

❶ case ARGV[0]

when "strona"
❷     rio(ARGV[1]) > rio("#{URI.parse(ARGV[1].strip).host}.html")
    exit
❸ when "rysunki"
    begin
        open(url, "User-Agent" => "Mozilla/4.0 (compatible; MSIE 5.5;
        ↪Windows 98)") do |source|
        source.each_line do |x|
```

```
            if x =~ /<img src="(.+.[jpeg|gif])"\s+/
                name = $1.split('"').first

                name = url + name if Pathname.new(name).absolute?
                    copy = name.split('/').last

                File.open(copy, 'wb') do |f|
                    f.write(open(name).read)
                end
            end
        end
    end
    rescue => e
        puts "Wystąpił błąd – spróbuj ponownie."
        puts e
    end
    exit
when "linki"
    links = File.open("links.txt","w+b")
    begin
❹       open(ARGV[1], "User-Agent" => "Mozilla/4.0 (compatible; MSIE 5.5;
        ↪Windows 98)") do |source|
❺           links.puts URI.extract(source, ['http', 'https'])
        end
    rescue => e
        puts "Wystąpił błąd – spróbuj ponownie."
        puts e
    end
    links.close
    exit
else
    puts "Podałeś nieprawidłową instrukcję – spróbuj ponownie."
    puts "Sposób użycia: scrape.rb [strona|rysunki|linki] <przetwarzany
adres URL>"
    exit
end
```

### *Uruchamianie kodu*

Aby uruchomić skrypt, wpisz następujące polecenie:

```
ruby scrape.rb [strona|rysunki|linki] http://przetwarzany_adres_url.com/
```

### *Dane wyjściowe*

Dane wyjściowe skryptu są różne w zależności od wybranej instrukcji. Możesz zapoznać się z przykładem z poprzedniego programu.

### *Jak działa ten skrypt?*

Skrypt udostępnia trzy opcje. Możesz pobrać dane za pomocą instrukcji `linki`, `rysunki` lub `strona`. Do obsługi tych opcji służy instrukcja `case` ❶. Można też zastosować blok `if/else`, jednak polecenie `case` jest bardziej przejrzyste. Jeśli użytkownik chce pobrać stronę, skrypt używa instrukcji `rio` do skopiowania kodu źródłowego dokumentu do pliku HTML na lokalnym komputerze ❷. Polecenie `rio` obsługuje tak wiele szczegółowych, żmudnych operacji, że zadanie to można wykonać w jednym wierszu kodu!

Następny blok wydobywa rysunki ❸. Ta sekcja to kopia kodu ze skryptu 45. — „Wydobywanie rysunków", dlatego nie będę szczegółowo omawiał tego fragmentu. Jeśli chcesz dowiedzieć się czegoś więcej, zajrzyj do opisu poprzedniego programu.

Ostatni fragment instrukcji `case` wydobywa odnośniki. W odróżnieniu od innych części skryptu w tej zrezygnowałem ze stosowania gotowych rozwiązań, aby przedstawić inny sposób pobierania adresów URL. W tym podejściu do pobierania kodu źródłowego służy metoda `open` biblioteki `open-uri` ❹, a następnie skrypt wywołuje metodę `URI.extract`, która wyszukuje odsyłacze HTTP i HTTPS ❺. Wyniki program zapisuje w pliku tekstowym *links.txt*.

# 47. Szyfrowanie po stronie klienta

**RSA_client.rb** W opisach technologii informacyjnych i zabezpieczeń często powtarzają się trzy zasady: poufności, integralności i dostępności. Każdy z tych komponentów wpływa na sposób interakcji użytkownika z danymi. Dwa następne skrypty mają wbudowane szyfrowanie RSA, co zapewnia poufność, i kodowanie SHA1, gwarantujące integralność informacji. Do przesyłania danych w tym programach służy sieciowe połączenie TCP.

### *Kod*

```
require 'socket'
require 'digest/sha1'

begin
    print "Uruchamianie klienta..."
❶   client = TCPSocket.new('localhost', 8887)

    puts "nawiązano połączenie!\n\n"

❷   temp = ""
    5.times do
        temp << client.gets
    end
    puts "Otrzymano 1024-bitowy klucz publiczny RSA!\n\n"

❸   public_key = OpenSSL::PKey::RSA.new(temp)
```

```
    msg = 'mpg123*"C:\Program Files\Windows Media
    ↪Player\mplayer2.exe"*ruby.mp3'
❹   sha1 = Digest::SHA1.hexdigest(msg)

❺   command = public_key.public_encrypt("#{sha1}*#{msg}")
    print "Przesyłanie polecenia..."

❻   client.send(command,0)

    puts "wysłane!"
rescue => e
    puts "Wystąpił poważny problem..."
    puts e
    retry
end

client.close
```

### *Uruchamianie kodu*

Aby włączyć skrypt, wpisz następującą instrukcję:

```
ruby RSA_client.rb
```

### *Dane wyjściowe*

Poniżej znajdują się dane wyjściowe, wyświetlane po udanym nawiązaniu połączenia i przesłaniu polecenia.

```
Uruchamianie klienta...nawiązano połączenie!

Otrzymano 1024-bitowy klucz publiczny RSA!

Przesyłanie polecenia...wysłane!
```

### *Jak działa ten skrypt?*

Działanie klienta rozpoczyna się od próby nawiązania połączenia TCP przy użyciu określonego adresu IP i numeru portu ❶. Jeśli operacja ta się powiedzie, skrypt przekaże do standardowego wyjścia tekst *nawiązano połączenie*. Następnie klient oczekuje na otrzymanie 1024-bitowego publicznego klucza szyfrującego RSA z serwera. Ten klucz skrypt zapisuje w zmiennej `tmp`, ponieważ do czasu przekształcenia danych na obiekt klucza RSA OpenSSL są one tylko niezrozumiałym łańcuchem znaków ❷. Po zainicjowaniu zmiennej `public_key` i zapisaniu w niej publicznego klucza RSI program potwierdza jego otrzymanie oraz może przystąpić do szyfrowania informacji ❸.

Skrypt przesyła dane, które zawierają nazwę odtwarzacza plików muzycznych. W systemie Linux jest to mpg123, a na platformie Windows — klasyczny odtwarzacz Media Player (plik *mplayer2.exe*). Oprócz nazwy aplikacji skrypt przekazuje nazwę pliku muzycznego — *ruby.mp3*. Ten plik znajduje się już na serwerze, dlatego program po prostu nakazuje serwerowi odtworzenie danego utworu. Poszczególne części łańcucha znaków z poleceniem są rozdzielone gwiazdką (*). Możesz w dowolny sposób zmodyfikować to polecenie i same dane, ponieważ program zaszyfruje je oraz prześle na serwer.

Następny krok to szyfrowanie informacji. Skrypt zapisuje omówiony wcześniej łańcuch znaków z zapytaniem w zmiennej `msg` i szyfruje przy użyciu publicznego klucza RSA otrzymanego z serwera. Przed zaszyfrowaniem danych program koduje komunikat za pomocą algorytmu SHA1 i zapisuje wygenerowany kod w zmiennej `sha1` ❹. Ten kod zostanie użyty po przesłaniu danych na serwer. Pamiętaj, że algorytm SHA1 jest jednostronny, dlatego jeśli w trakcie przekazywania danych zostaną one zmodyfikowane, pierwotny i nowy kod będą się od siebie różnić.

Następnie skrypt scala zmienne `sha1` i `msg`, łącząc je gwiazdką. Do szyfrowania danych wyjściowych służy metoda `public_encrypt` obiektu klucza RSA ❺. Jak może zgadłeś, metoda ta szyfruje informacje przy użyciu publicznego klucza RSA. Tylko odpowiadający mu prywatny klucz RSA pozwala odszyfrować komunikat.

Na zakończenie skrypt przesyła zaszyfrowany komunikat na serwer i zamyka połączenie ❻. Jeśli w trakcie szyfrowania lub przesyłania danych wystąpią problemy, sytuację pozwoli uratować zaufany blok `begin/rescue`. Jeżeli wszystkie operacje zakończą się sukcesem, serwer odtworzy fantastyczne dźwięki związane z językiem Ruby! Czy jest w życiu coś piękniejszego od słuchania piosenek o języku Ruby?

# 48. Szyfrowanie po stronie serwera

**RSA_server.rb** Po zapoznaniu się z klientem i jego kodem pora przyjrzeć się serwerowi. Przyjmuje on dane, sprawdza, czy kod SHA1 jest poprawny, odszyfrowuje informacje i wykonuje polecenie z przesłanego łańcucha znaków.

## *Kod*

```
require 'openssl'
require 'socket'
require 'digest/sha1'

❶ priv_key = OpenSSL::PKey::RSA.new(1024)
pub_key = priv_key.public_key

host = ARGV[0] || 'localhost'
port = (ARGV[1] || 8887).to_i

❷ server = TCPServer.new(host, port)
```

```
❸ while session = server.accept
      begin
          puts "Nawiązano połączenie...trwa wysyłanie klucza
          ↪publicznego.\n\n"
          puts pub_key
❹         session.print pub_key
          puts "Przesłano klucz publiczny – trwa oczekiwanie na
          ↪dane...\n\n"

❺         temp = session.recv(10000)
          puts "Otrzymano dane..."

❻         msg = priv_key.private_decrypt(temp)
      rescue => e
          puts "Wystąpił poważny problem przy pobieraniu i odszyfrowywaniu
          ↪danych."
          puts e
      end

❼     command = msg.split("*")

      serv_hash = command[0]
      nix_app = command[1]
      win_app = command[2]
      file = command[3]

❽     if Digest::SHA1.hexdigest("#{nix_app}*#{win_app}*#{file}")==serv_hash
          puts "Potwierdzono integralność komunikatu..."
❾         if RUBY_PLATFORM.include?('mswin32')
              puts "Uruchamianie polecenia dla systemu Windows: #{win_app}
              ↪#{file}"
              `#{win_app} #{file}`
              exit
❿          else
              puts "Uruchamianie polecenia dla systemu Linux: #{nix_app}
              ↪#{file}"
              `#{nix_app} #{file}`
              exit
          end
      else
          puts "Nie można przeprowadzić walidacji komunikatu!"
      end
      exit
end
```

### *Uruchamianie kodu*

W celu uruchomienia skryptu wpisz poniższe polecenie:

```
ruby RSA_server.rb
```

### Dane wyjściowe

Poniżej znajdują się dane wyjściowe, wyświetlane po udanym nawiązaniu połączenia i przesłaniu polecenia.

```
Nawiązano połączenie...trwa wysyłanie klucza publicznego.

-----BEGIN RSA PUBLIC KEY-----
MIGJAoGBAMe12IJIyVULS/OLlHeekhZNyh2YhuGfJSwEozw2Z6GfaRjZg7sOcwqb
B/Z+MMUPIjCmiH38pkKzh5GhA8zcRSWEFtssa8HcyIowA5ftZM27/6diYz9kNueI
NO2kvlkqwU5KUOKnLISJnrZAlTbJMqio24dn3PNm27kgae8+KdrHAgMBAAE=
-----END RSA PUBLIC KEY-----
Przesłano klucz publiczny – trwa oczekiwanie na dane...

Otrzymano dane...
Potwierdzono integralność komunikatu...
Wykonywanie polecenia dla systemu Windows: "C:\Program Files\Windows Media
Player\mplayer2.exe" ruby.mp3
```

### Jak działa ten skrypt?

Skrypt generuje najpierw niepowtarzalny prywatny klucz RSA ❶. Na podstawie tego klucza powstaje publiczny klucz RSA. Do jego wygenerowania służy metoda `public_key` obiektu klucza RSA. Przy każdym uruchomieniu program tworzy nową parę kluczy. Jeśli klient prześle dane zaszyfrowane przy użyciu dawnego klucza publicznego, serwer nie zdoła odszyfrować komunikatu.

Po utworzeniu kluczy RSA skrypt inicjuje serwer TCP ❷. Serwer ten należy uruchomić przy użyciu argumentów w postaci nazwy serwera i portu, które można podać w wierszu poleceń. Jeśli te argumenty nie są dostępne, skrypt używa ustawień domyślnych. Kiedy serwer jest już gotowy, rozpoczyna oczekiwanie na połączenia. Pętla `while` umożliwia zarządzanie w skrypcie sesjami ❸. Ponieważ program nie jest wielowątkowy, w danym momencie obsługuje tylko jedno połączenie.

Kiedy użytkownik uruchomi klienta, ten nawiąże połączenie z serwerem. Spowoduje to rozpoczęcie nowej sesji, a pierwsza operacja w niej polega na przesłaniu przez serwer publicznego klucza RSA ❹. Klucz RSA jest mały, dlatego jego przekazywanie trwa krótko. Następnie skrypt oczekuje na przesłanie danych przez klienta. W tym czasie klient otrzymuje publiczny klucz RSA i szyfruje przesyłany komunikat. W zmiennej `temp` skrypt zapisuje dane odebrane przez serwer przy użyciu połączenia TCP. Limit tych informacji to 10 000 bajtów ❺. Dopiero po odebraniu danych program przechodzi do dalszych działań.

Przy użyciu metody `private_decrypt` obiektu klucza RSA skrypt odszyfrowuje dane ze zmiennej `temp` i zapisuje je w zmiennej `msg` ❻. Jeśli w czasie pobierania i odszyfrowywania łańcucha znaków z poleceniem wystąpią błędy, klauzula `rescue` przechwyci je i wyświetli przydatne informacje, które pomogą rozwiązać problem.

Jak pewnie sobie przypominasz z opisu skryptu 47. — „Szyfrowanie po stronie klienta", łańcuch znaków z poleceniem jest ograniczony gwiazdką (*). Dlatego aby pobrać właściwy fragment tekstu, należy użyć metody `split` i podać gwiazdkę jako ogranicznik zastosowany w łańcuchu `msg` ❼. Dane wyjściowe skrypt zapisuje w zmiennej `command`, która przechowuje tablicę łańcuchów znaków. Ponieważ tekst powstaje w skrypcie klienckim, wiadomo, z jakich fragmentów się składa. Na początku znajduje się kod SHA1, następnie nazwa aplikacji dla systemu Linux, nazwa programu dla platformy Windows i przeznaczony do użycia plik.

Do utworzenia kodu SHA1 służy instrukcja dla systemu Linux, polecenie dla platformy Windows i nazwa pliku ❽. Między poszczególnymi częściami łańcucha znaków znajdują się gwiazdki, co pozwala odtworzyć pierwotny tekst. Efekt jego zakodowania jest porównywany z wartością zmiennej `serv_hash`, która zawiera kod SHA1 przesłany przez klienta. Jeśli porównywane kody nie są sobie równe, dane musiały ulec zmianie w trakcie ich przesyłania. Nie można ufać takim informacjom, dlatego program kończy działanie. Miejmy jednak nadzieję, że oba kody będą takie same, a skrypt wykona dalsze operacje.

Po potwierdzeniu integralności komunikatów program musi wybrać uruchamianą aplikację. Ruby umożliwia łatwe określenie używanego systemu. Wystarczy o to zapytać przy użyciu wyrażenia `RUBY_PLATFORM`. Jeśli korzystasz z systemu Windows, wartość tego wyrażenia to `i386-mswin32`. Przy użyciu wygodnej metody `include?` skrypt sprawdza, czy łańcuch znaków z wyrażenia `RUBY_PLATFORM` zawiera fragment `mswin32` ❾. Jeśli ten test zwróci wartość `true`, program wywoła polecenie dla systemu Windows. W przeciwnym razie uruchomiona zostanie aplikacja dla platformy Linux ❿. W obu przypadkach jeżeli wszystkie operacje przebiegną prawidłowo, system powinien uruchomić program muzyczny i rozpocząć odtwarzanie pliku *ruby.mp3*. Skrypt kończy działanie po zamknięciu aplikacji muzycznej. W ten sposób można komunikować się w poufny sposób, a jednocześnie zachować integralność danych.