Úklid a čištění jako věda

A take zpráva o jednom vítězství

Pavel Pecina

Michal Marek, Miroslav Spousta

Ústav formální a aplikované lingvistiky
Matematicko-fyzikální fakulta Univerzity Karlovy

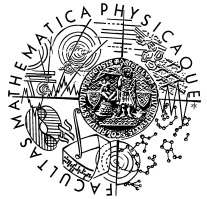

Mixer, 21.listopad, 2007

Motivace

WAC3 - 2007

Web as Corpus 2007, UCLouvain, Louvain-la-Neuve, September 15-16 2007 (Belgium)

WAC3

- Call for papers
- Submit a paper
- Registration
- Program
- Scientific committee
- Travel info. & venue
- Local organisation team
- Associated events
- SIGWAC
- Previous Workshops
- Pictures

Cleaneval

- Information
- Scientific committee

Organisation

UCL Université catholique de Louvain

SIGWAC

SIGWAC is the Special Interest Group of the Association for Computational Linguistics (ACL) on Web as Corpus
Its objectives are

- to promote interest in the use of the web as a source of linguistic data, and as an object of study in its own right;
- to provide members of the ACL with a special interest in the web-as-corpus with a means of exchanging news of recent research developments and other matters of interest;
- to sponsor meetings and workshops on the web as corpus that appear to be timely and worthwhile.

More info on SIGWAC

Last update : **July, 2007**

Motivace

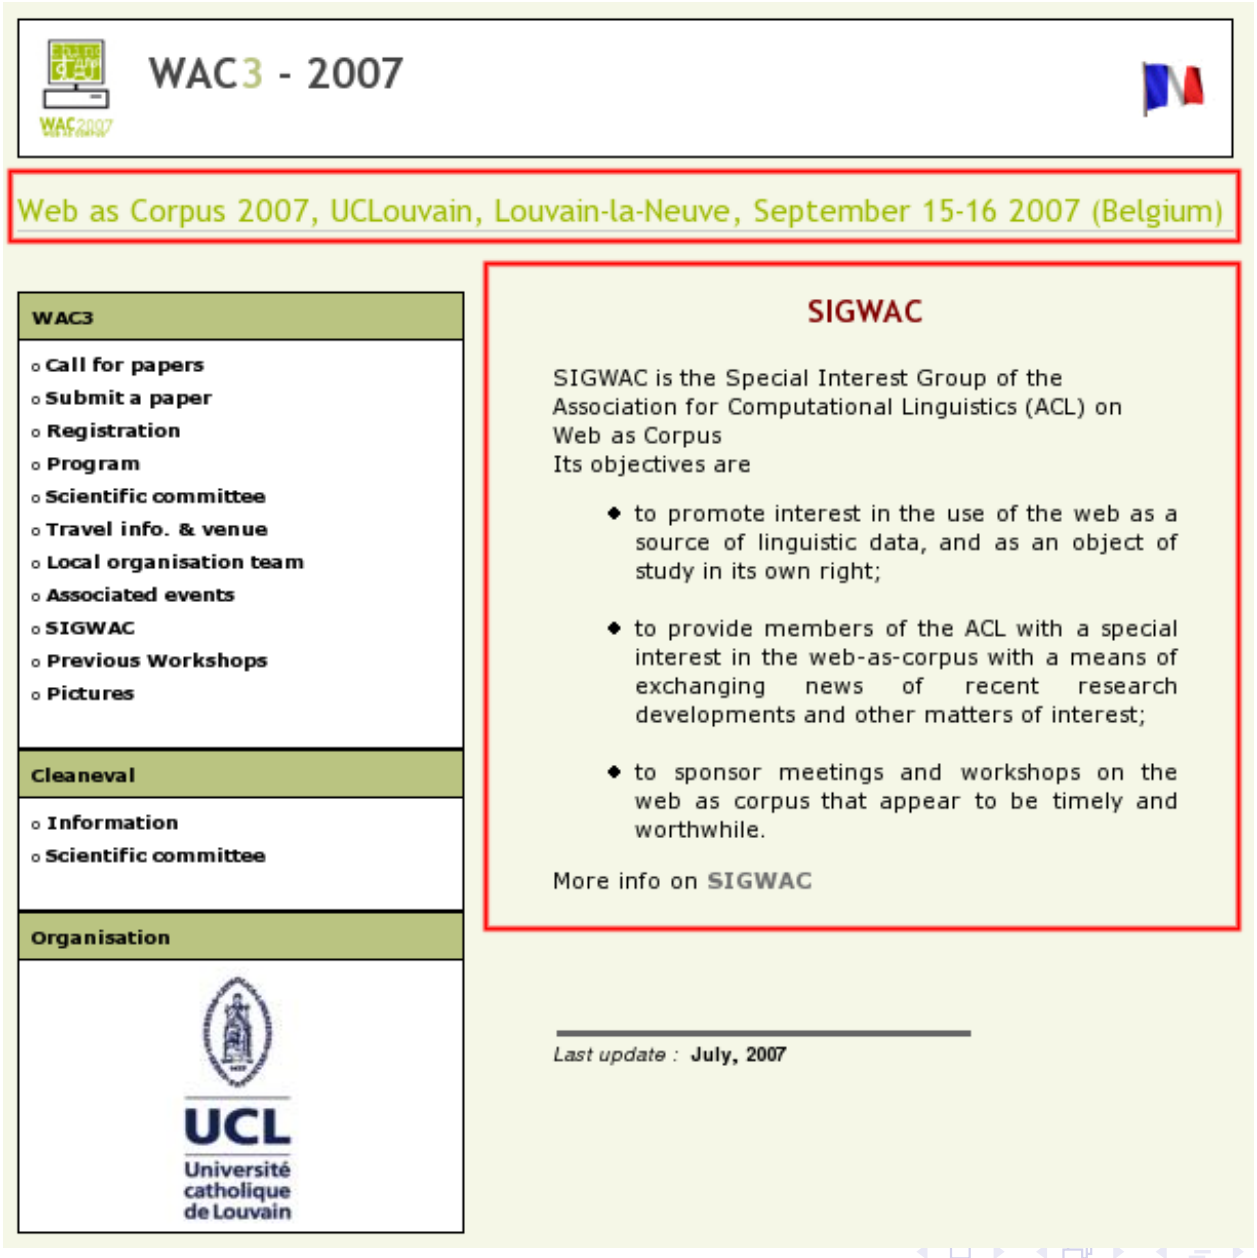

WAC3 - 2007

Web as Corpus 2007, UCLouvain, Louvain-la-Neuve, September 15-16 2007 (Belgium)

WAC3

- Call for papers
- Submit a paper
- Registration
- Program
- Scientific committee
- Travel info. & venue
- Local organisation team
- Associated events
- SIGWAC
- Previous Workshops
- Pictures

Cleaneval

- Information
- Scientific committee

Organisation

UCL Université catholique de Louvain

SIGWAC

SIGWAC is the Special Interest Group of the Association for Computational Linguistics (ACL) on Web as Corpus
Its objectives are

- to promote interest in the use of the web as a source of linguistic data, and as an object of study in its own right;
- to provide members of the ACL with a special interest in the web-as-corpus with a means of exchanging news of recent research developments and other matters of interest;
- to sponsor meetings and workshops on the web as corpus that appear to be timely and worthwhile.

More info on SIGWAC

Last update : **July, 2007**

Motivace

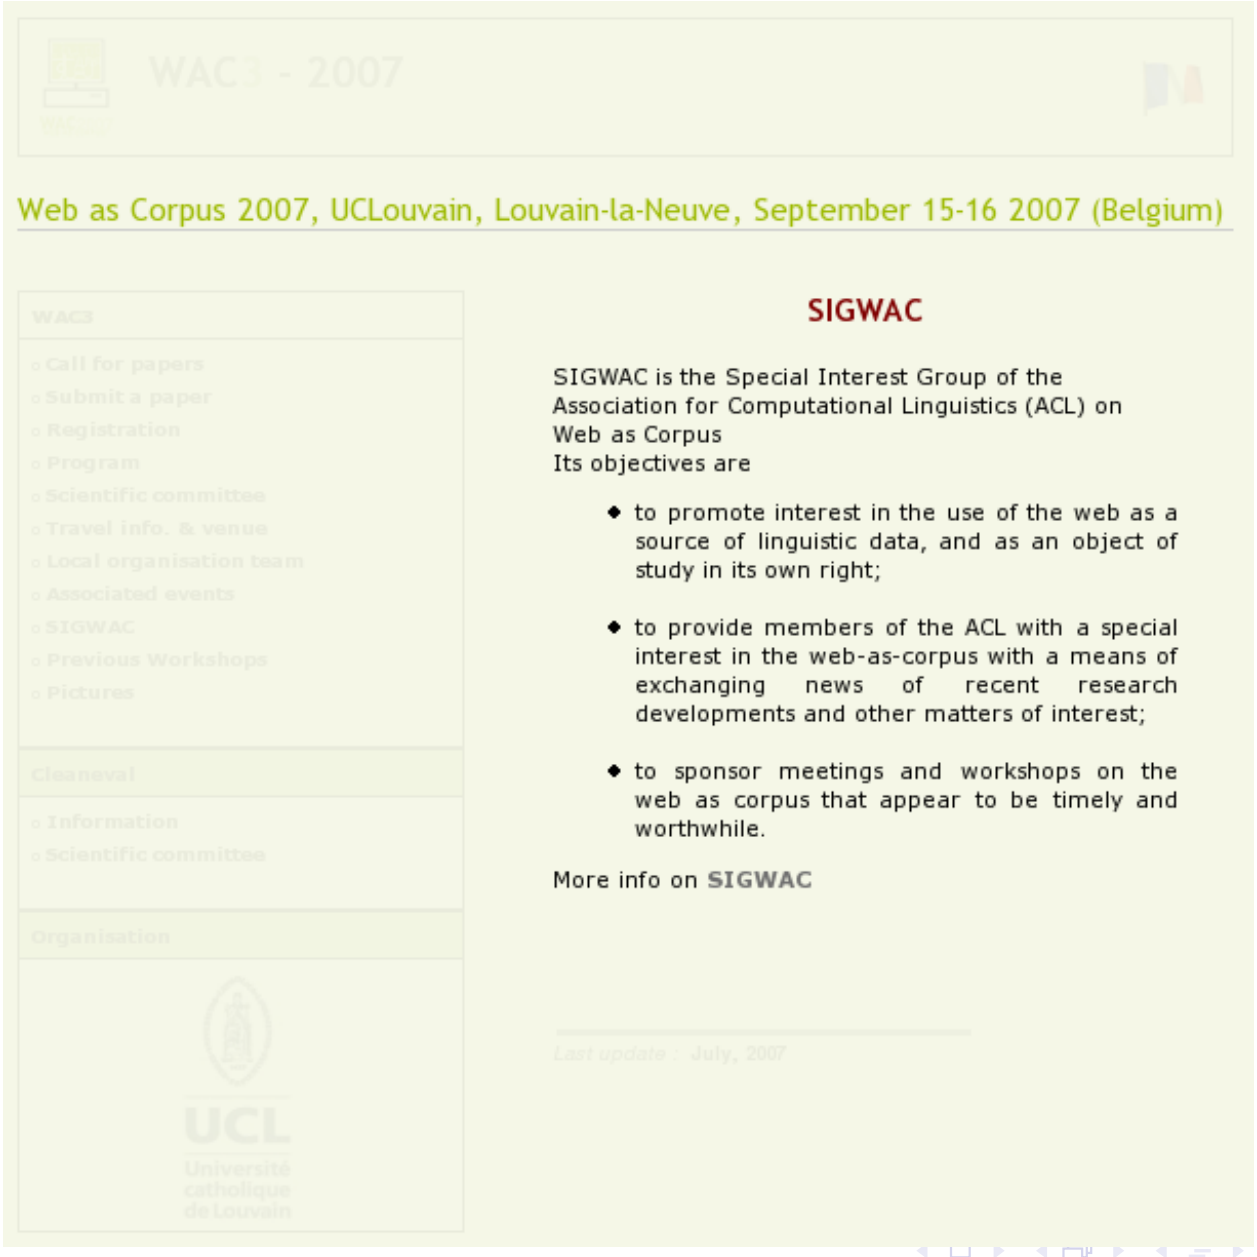

WAC3 - 2007

Web as Corpus 2007, UCLouvain, Louvain-la-Neuve, September 15-16 2007 (Belgium)

WAC3
- Call for papers
- Submit a paper
- Registration
- Program
- Scientific committee
- Travel info. & venue
- Local organisation team
- Associated events
- SIGWAC
- Previous Workshops
- Pictures

Cleaneval
- Information
- Scientific committee

Organisation

UCL Université catholique de Louvain

SIGWAC

SIGWAC is the Special Interest Group of the Association for Computational Linguistics (ACL) on Web as Corpus
Its objectives are

- to promote interest in the use of the web as a source of linguistic data, and as an object of study in its own right;
- to provide members of the ACL with a special interest in the web-as-corpus with a means of exchanging news of recent research developments and other matters of interest;
- to sponsor meetings and workshops on the web as corpus that appear to be timely and worthwhile.

More info on SIGWAC

Last update : July, 2007

Aplikace

1. **Indexování webových stránek pro vyhledávání**
   - text (slova), který nesouvisí s obsahem stránky, je pro indexaci nevhodný,
     vyhledání na základě takových slov nevede k nalezení relevantní stránky
   - vyčištěná stránka se dál neprezentuje,
     při vyhledávní se odkazuje na původní stránku
   - při čištění důraz kladen na recall,
     nízkou precision "zachrání" indexační algoritmus

2. **Vytváření webových korpusů pro lingvistické účely**
   - text, který nesouvisí s obsahem stránky, není pro takové využití vhodný
     fragmentace, opakující se slova, chybějící segmentace, negramatičnost
   - čištění se provádí jaka základní předzpracování,
     veškerá další zpracování probíhá až následně na vyčištěných datech
   - při čištění důraz kladen na precision,
     nízký recall lze "dohnat" zpracováním většího množství dat

Web jako korpus

Idea

- využití dat dostupných na internetu jako zdroje lingvistické evidence
- buď jako klasické korpusy nebo jako kolekce pro vyhledávání informací
- zaměření na textová data (zatím!)

Přístupy

- **vzdálený** – využití vyhledávacích služeb jako rozhraní k přístupu k datům, *pravděpodobnost řetezce slov odhadnuta na základě počtu "hitů"*
- **lokální** – automatické stahování dat a vytváření klasického korpusu

Problémy

- stahování: *technologie, infrastruktura*
- detekce kódování a identifikace jazyka
- čištění: *odstranění nežádoucích částí*

Čištění webových stránek

Postup

1. odlišit zrno od plev
2. zrno ponechat
3. plevy vyhodit

Plevy

- menu, navigační panely
- seznamy (interních i externích) odkazů
- copyrightové informace
- hlavičky, patičky a další prvky šablon
- reklama

Zrno

- text, který tvoří “obsah” stránky
- strukturován pomocí následujících značek:

<h> nadpisy
<p> odstavce
<l> položky seznamů

Příklad

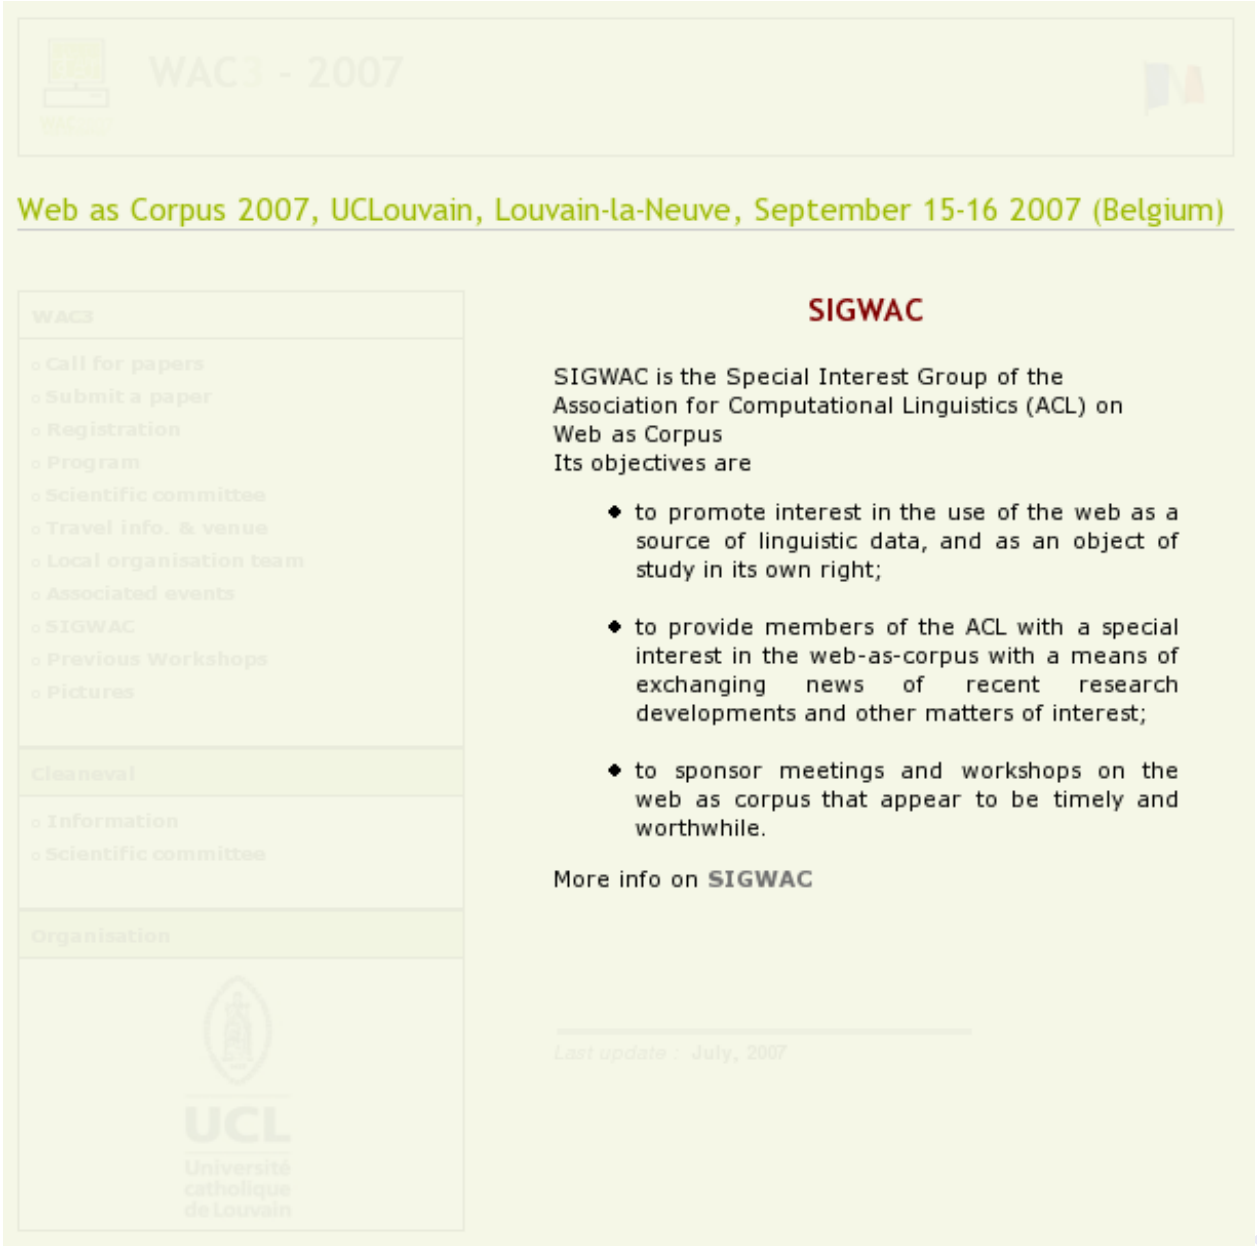

WAC3 - 2007

Web as Corpus 2007, UCLouvain, Louvain-la-Neuve, September 15-16 2007 (Belgium)

WAC3
- Call for papers
- Submit a paper
- Registration
- Program
- Scientific committee
- Travel info. & venue
- Local organisation team
- Associated events
- SIGWAC
- Previous Workshops
- Pictures

Cleaneval
- Information
- Scientific committee

Organisation

UCL Université catholique de Louvain

SIGWAC

SIGWAC is the Special Interest Group of the Association for Computational Linguistics (ACL) on Web as Corpus
Its objectives are

- to promote interest in the use of the web as a source of linguistic data, and as an object of study in its own right;
- to provide members of the ACL with a special interest in the web-as-corpus with a means of exchanging news of recent research developments and other matters of interest;
- to sponsor meetings and workshops on the web as corpus that appear to be timely and worthwhile.

More info on SIGWAC

Last update : July, 2007

<h>Web as Corpus 2007, UCLouvain, Louvain-la-Neuve, September 15-16 2007 (Belgium)

<h>SIGWAC

<p>SIGWAC is the Special Interest Group of the Association for Computational Linguistics (ACL) on Web as Corpus Its objectives are

<l>to promote interest in the use of the web as a source of linguistic data, and as an object of study in its own right;

<l>to provide members of the ACL with a special interest in the web-as-corpus with a means of exchanging news of recent research developments and other matters of interest;

<l>to sponsor meetings and workshops on the web as corpus that appear to be timely and worthwhile.

<p>More info on SIGWAC

Příklad

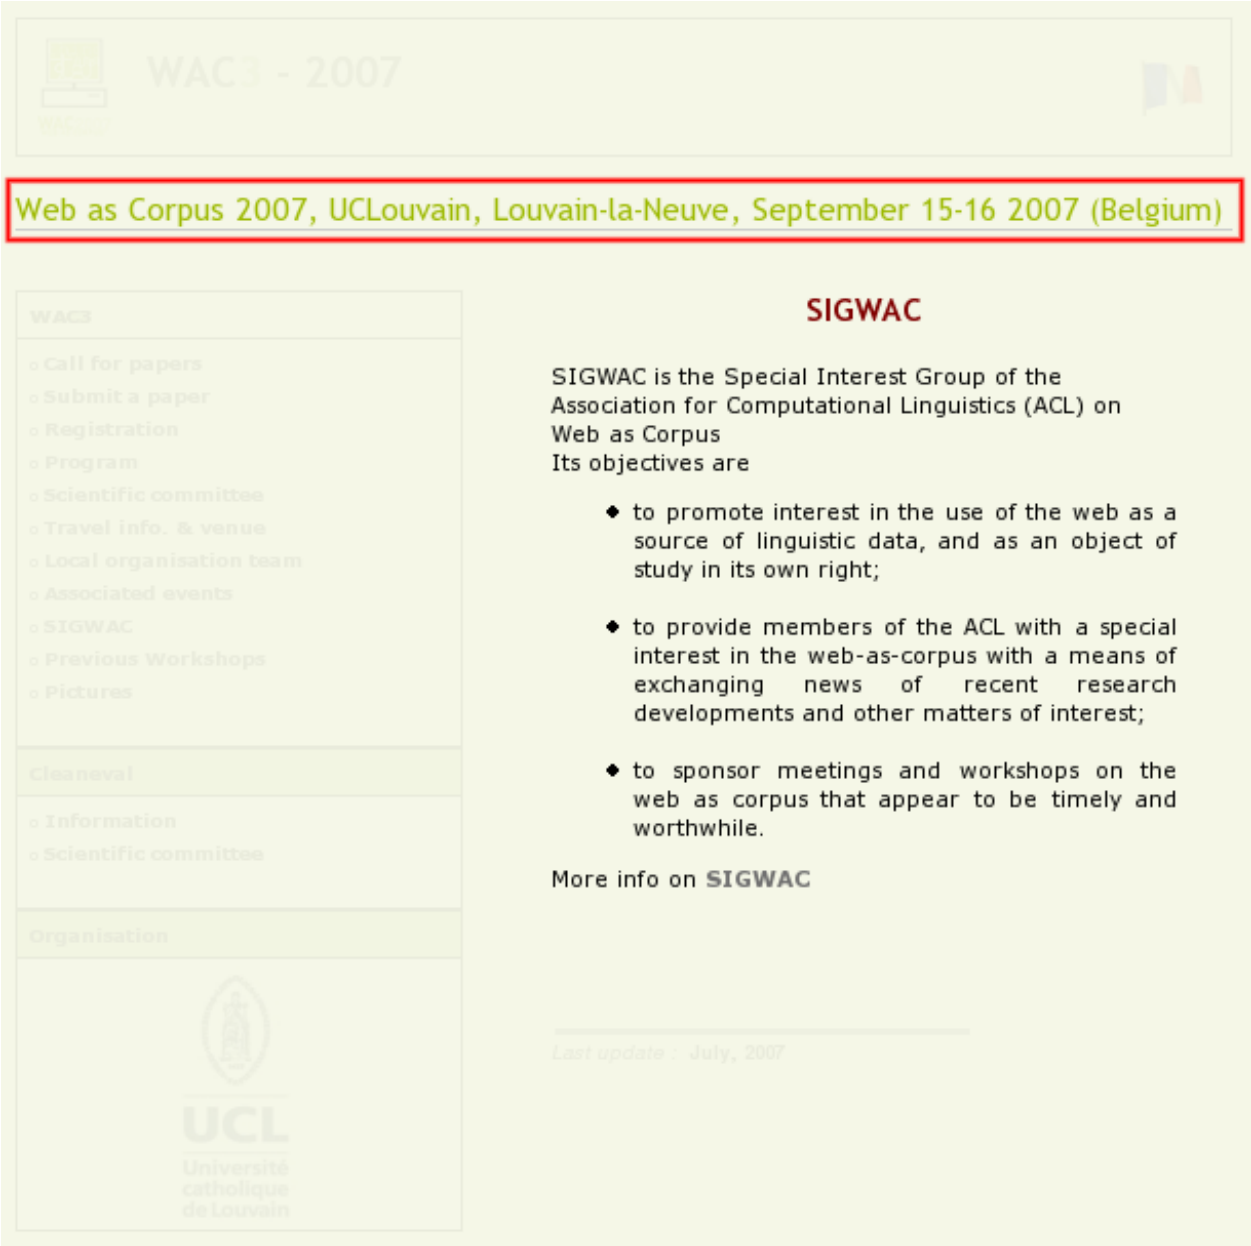

<h>Web as Corpus 2007, UCLouvain, Louvain-la-Neuve, September 15-16 2007 (Belgium)

<h>SIGWAC

<p>SIGWAC is the Special Interest Group of the Association for Computational Linguistics (ACL) on Web as Corpus Its objectives are

<l>to promote interest in the use of the web as a source of linguistic data, and as an object of study in its own right;

<l>to provide members of the ACL with a special interest in the web-as-corpus with a means of exchanging news of recent research developments and other matters of interest;

<l>to sponsor meetings and workshops on the web as corpus that appear to be timely and worthwhile.

<p>More info on SIGWAC

Příklad

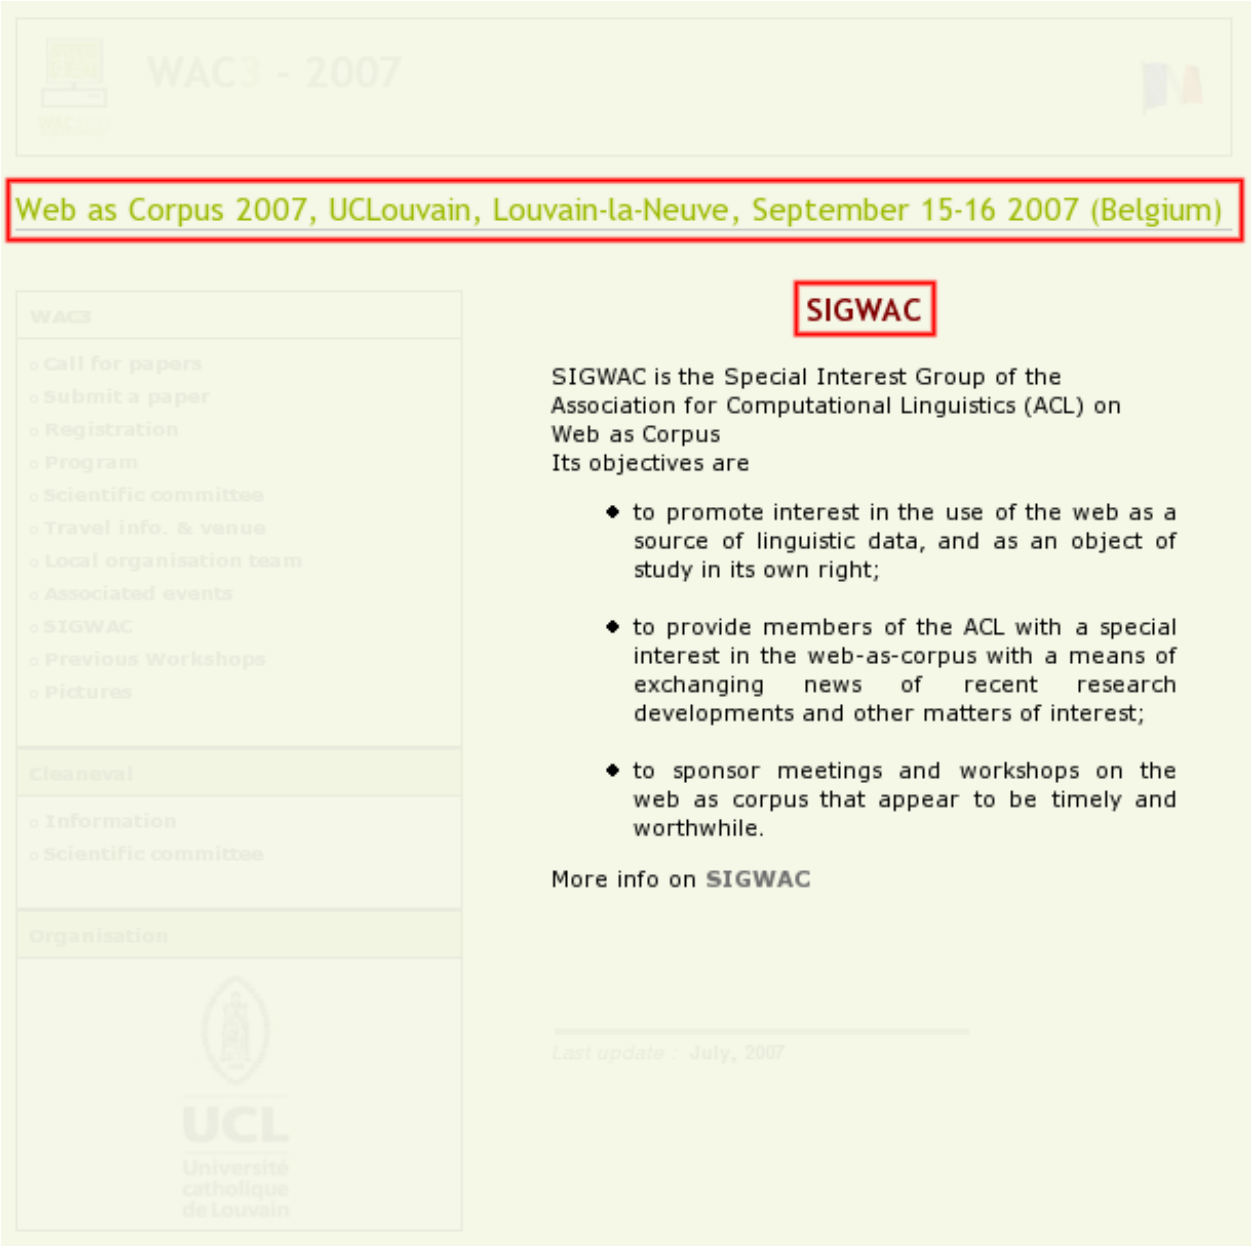

<h>Web as Corpus 2007, UCLouvain, Louvain-la-Neuve, September 15-16 2007 (Belgium)

<h>SIGWAC

<p>SIGWAC is the Special Interest Group of the Association for Computational Linguistics (ACL) on Web as Corpus Its objectives are

<l>to promote interest in the use of the web as a source of linguistic data, and as an object of study in its own right;

<l>to provide members of the ACL with a special interest in the web-as-corpus with a means of exchanging news of recent research developments and other matters of interest;

<l>to sponsor meetings and workshops on the web as corpus that appear to be timely and worthwhile.

<p>More info on SIGWAC

Příklad

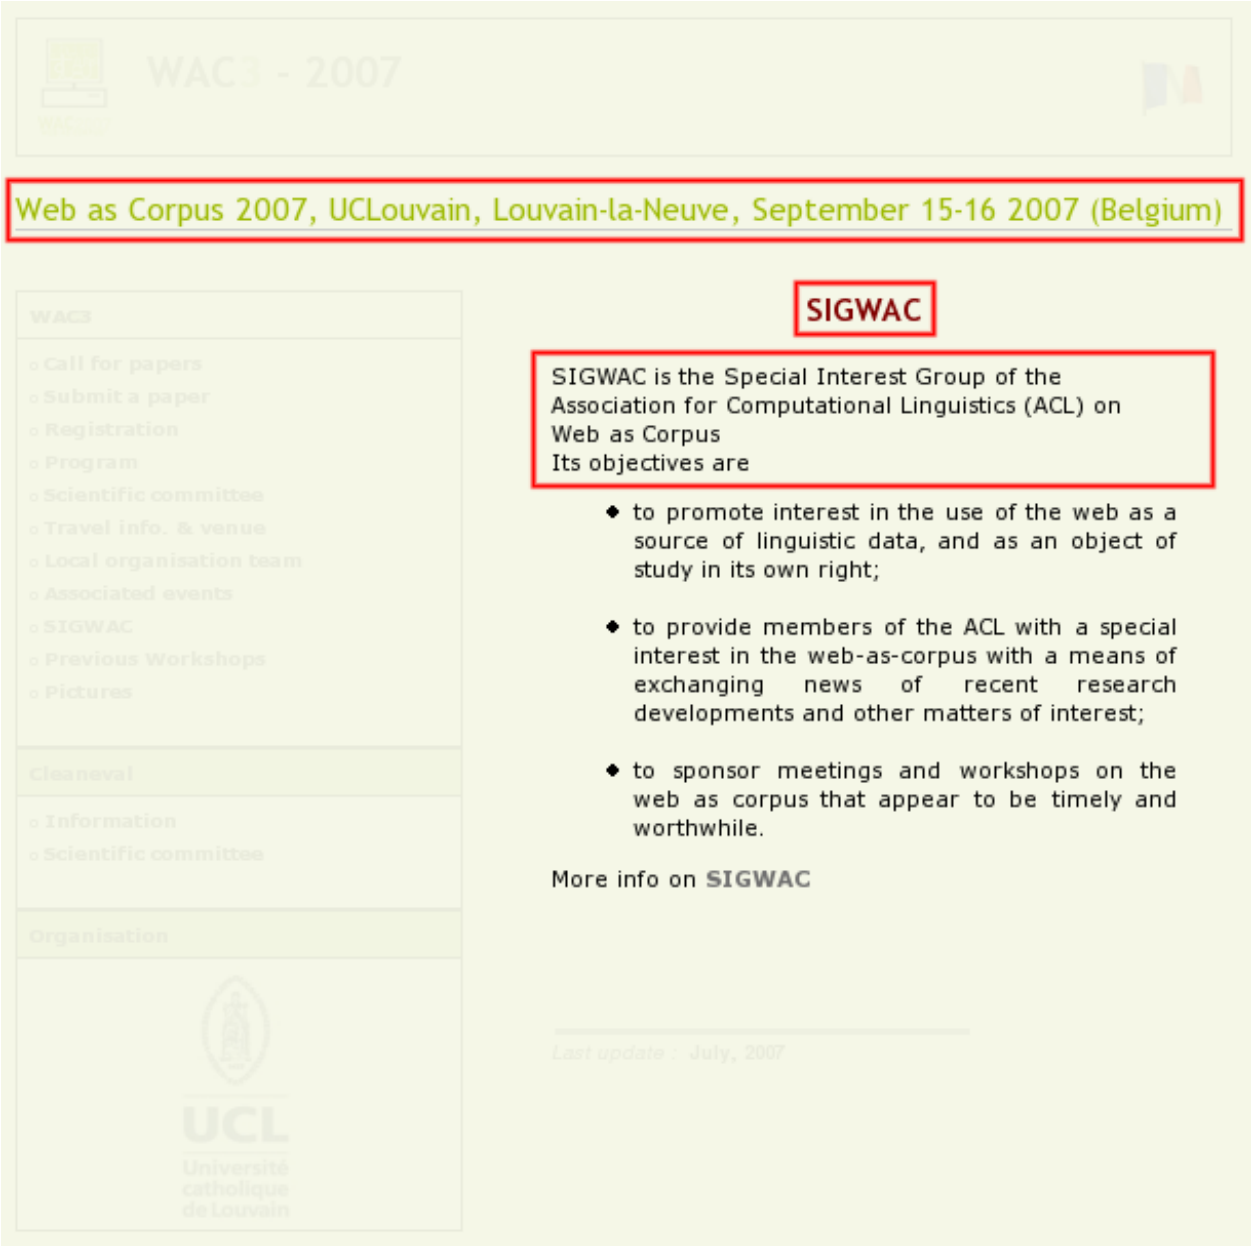

<h>Web as Corpus 2007, UCLouvain, Louvain-la-Neuve, September 15-16 2007 (Belgium)

<h>SIGWAC

<p>SIGWAC is the Special Interest Group of the Association for Computational Linguistics (ACL) on Web as Corpus Its objectives are

<l>to promote interest in the use of the web as a source of linguistic data, and as an object of study in its own right;

<l>to provide members of the ACL with a special interest in the web-as-corpus with a means of exchanging news of recent research developments and other matters of interest;

<l>to sponsor meetings and workshops on the web as corpus that appear to be timely and worthwhile.

<p>More info on SIGWAC

Příklad

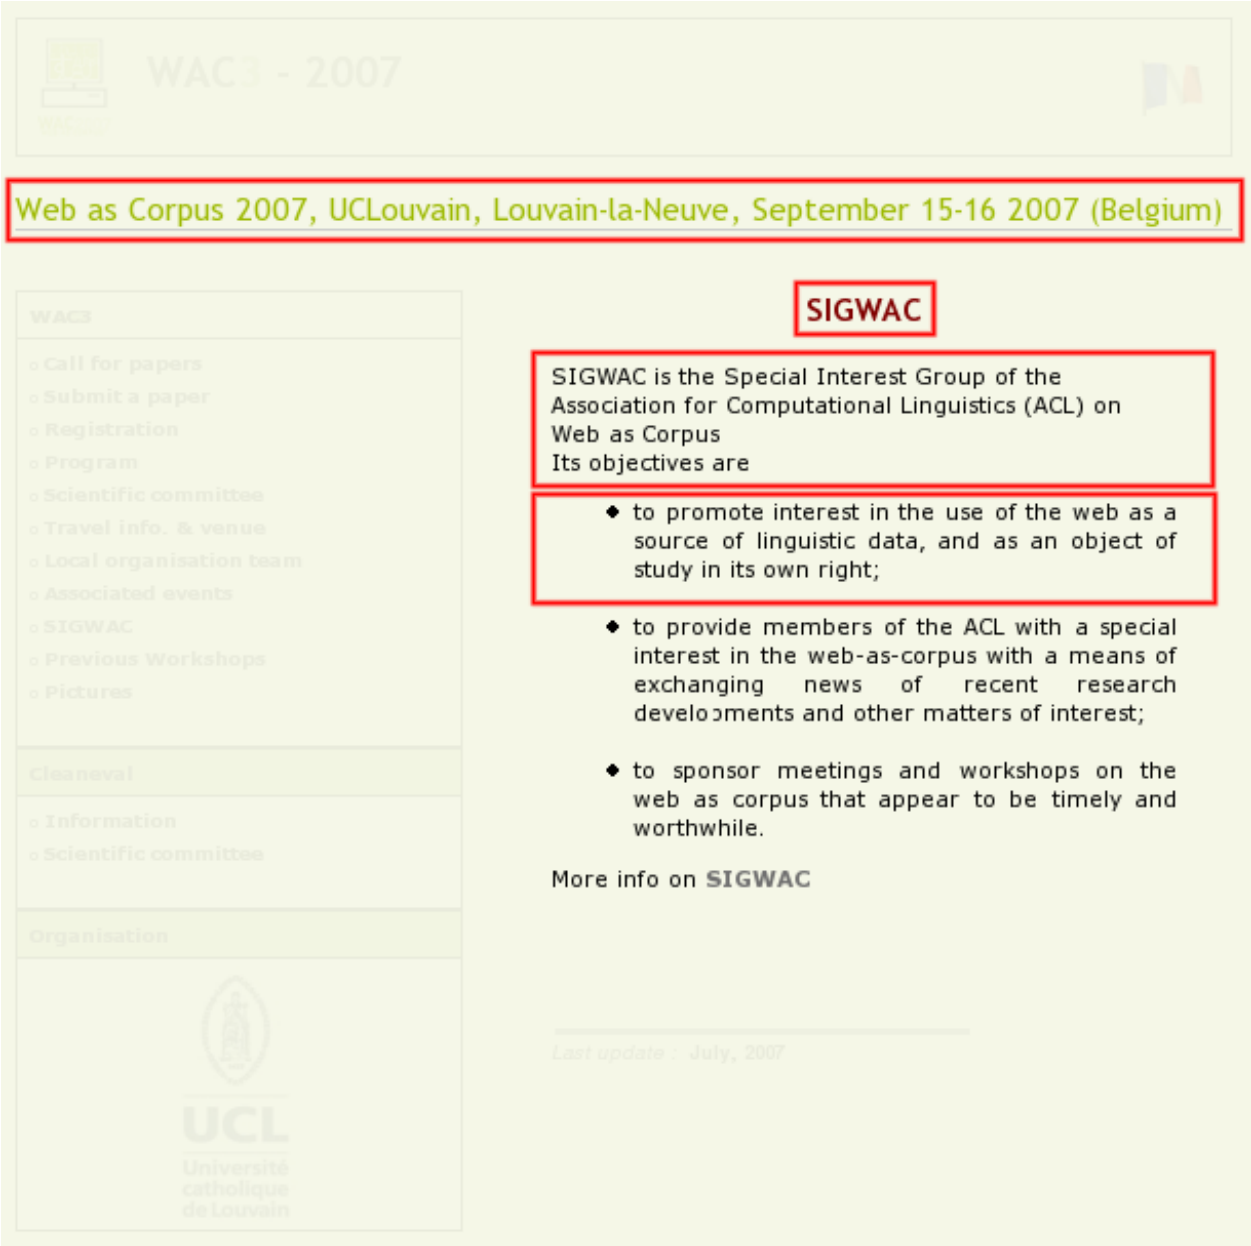

<h>Web as Corpus 2007, UCLouvain, Louvain-la-Neuve, September 15-16 2007 (Belgium)

<h>SIGWAC

<p>SIGWAC is the Special Interest Group of the Association for Computational Linguistics (ACL) on Web as Corpus Its objectives are

<l>to promote interest in the use of the web as a source of linguistic data, and as an object of study in its own right;

<l>to provide members of the ACL with a special interest in the web-as-corpus with a means of exchanging news of recent research developments and other matters of interest;

<l>to sponsor meetings and workshops on the web as corpus that appear to be timely and worthwhile.

<p>More info on SIGWAC

Příklad

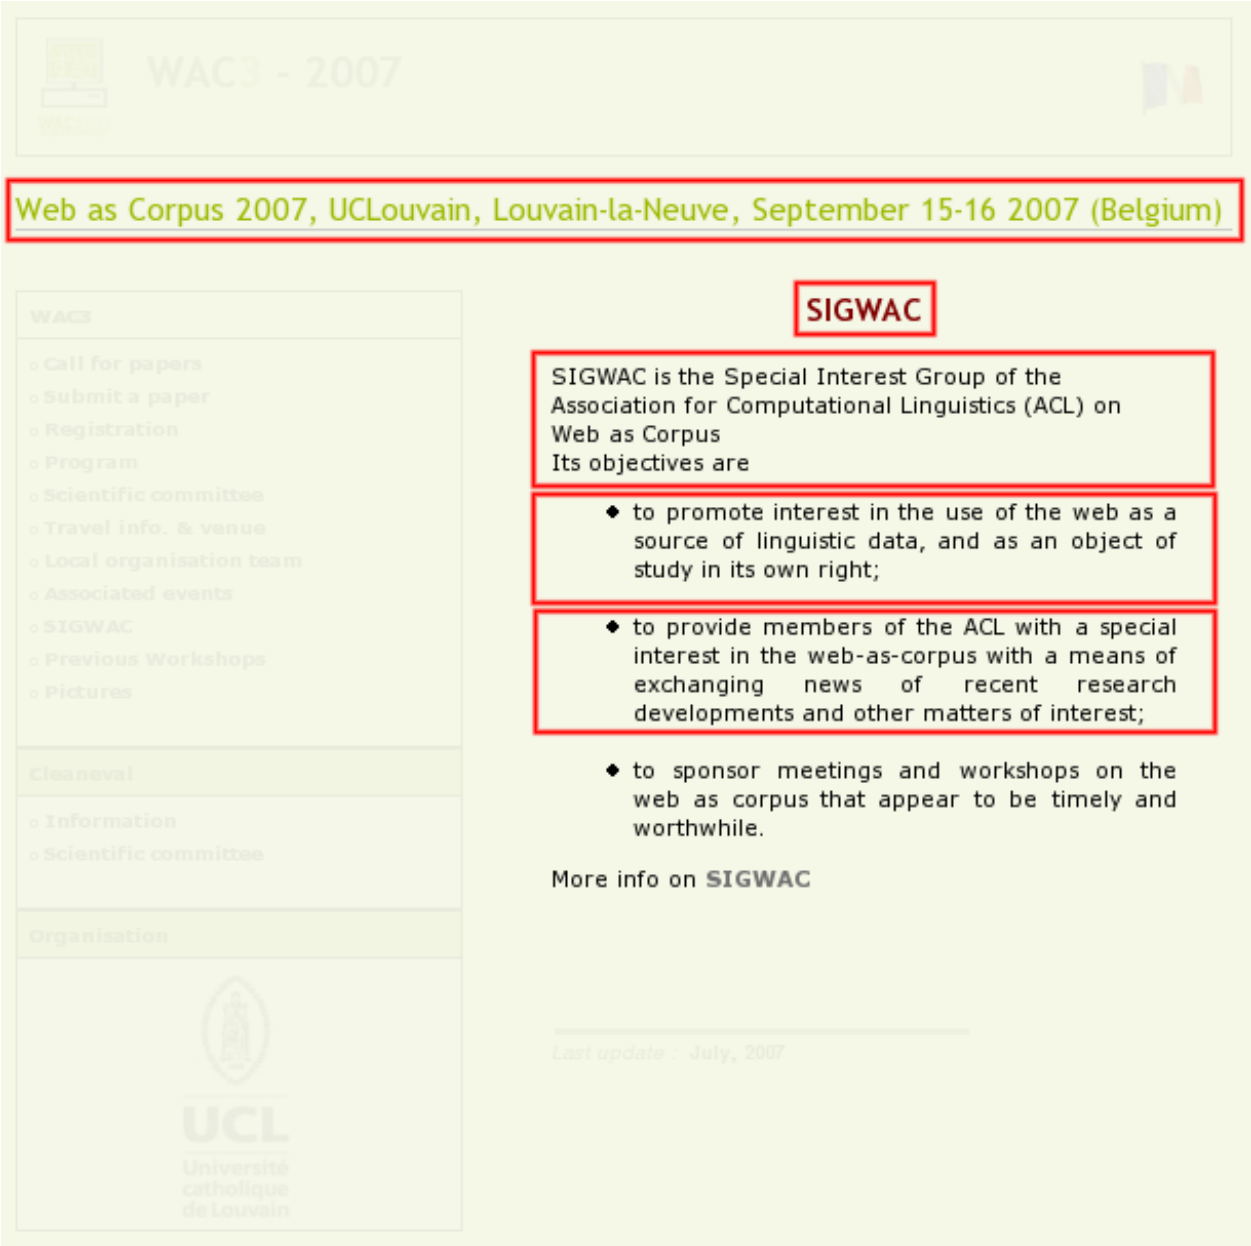

<h>Web as Corpus 2007, UCLouvain, Louvain-la-Neuve, September 15-16 2007 (Belgium)

<h>SIGWAC

<p>SIGWAC is the Special Interest Group of the Association for Computational Linguistics (ACL) on Web as Corpus Its objectives are

<l>to promote interest in the use of the web as a source of linguistic data, and as an object of study in its own right;

<l>to provide members of the ACL with a special interest in the web-as-corpus with a means of exchanging news of recent research developments and other matters of interest;

<l>to sponsor meetings and workshops on the web as corpus that appear to be timely and worthwhile.

<p>More info on SIGWAC

Příklad

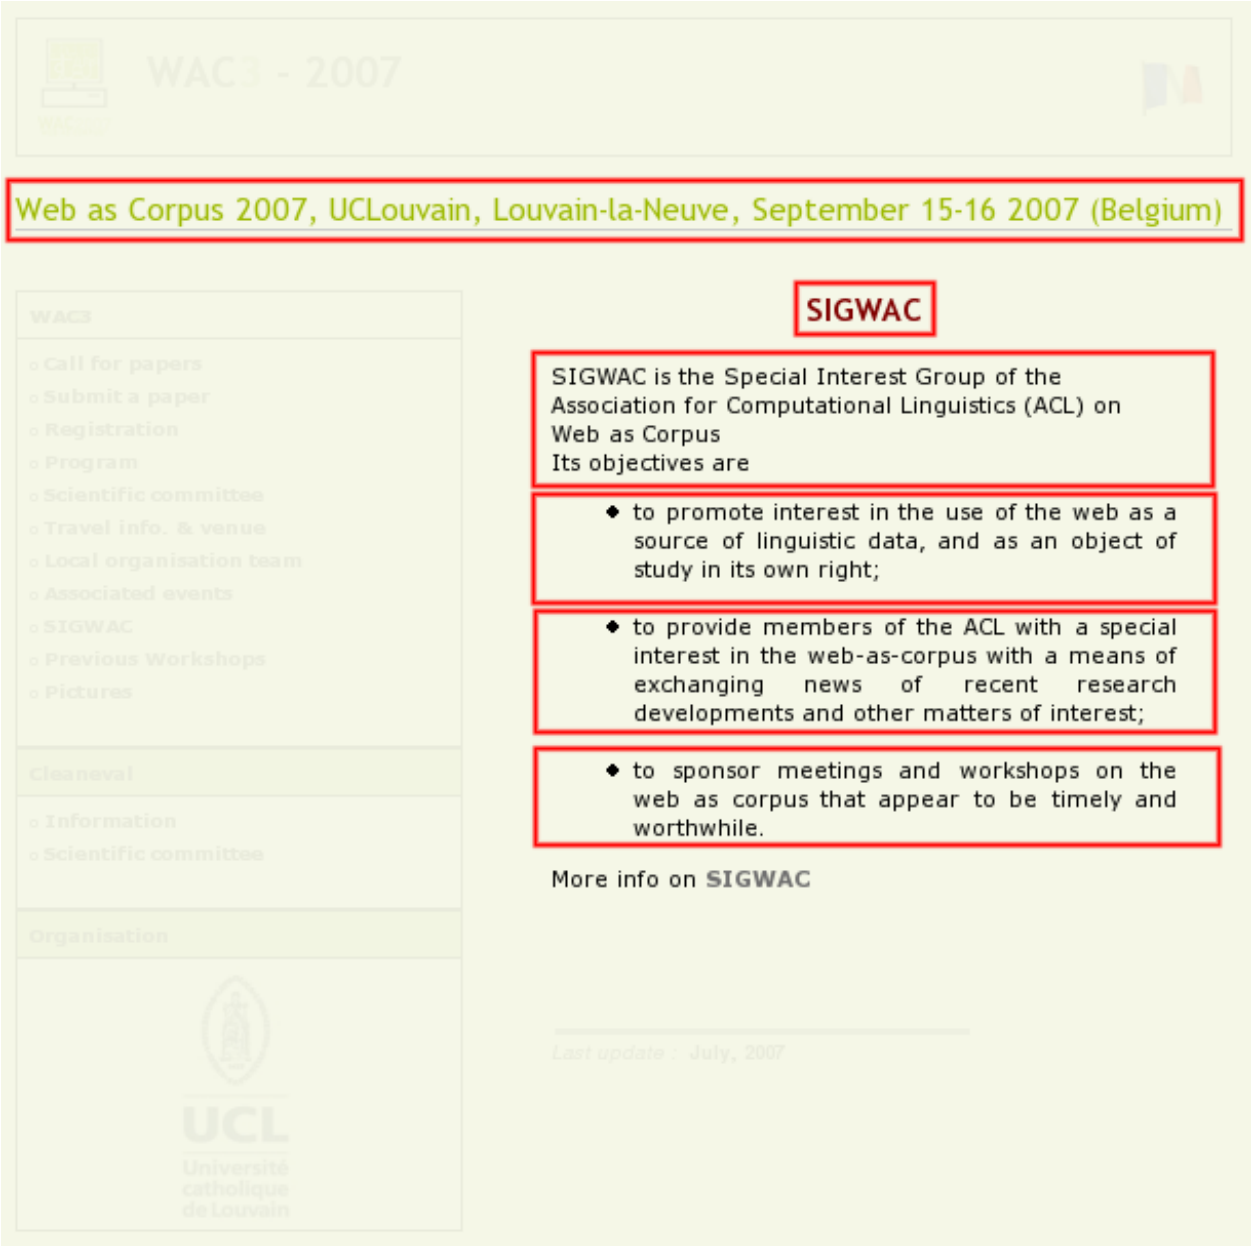

<h>Web as Corpus 2007, UCLouvain, Louvain-la-Neuve, September 15-16 2007 (Belgium)

<h>SIGWAC

<p>SIGWAC is the Special Interest Group of the Association for Computational Linguistics (ACL) on Web as Corpus Its objectives are

<l>to promote interest in the use of the web as a source of linguistic data, and as an object of study in its own right;

<l>to provide members of the ACL with a special interest in the web-as-corpus with a means of exchanging news of recent research developments and other matters of interest;

<l>to sponsor meetings and workshops on the web as corpus that appear to be timely and worthwhile.

<p>More info on SIGWAC

Příklad

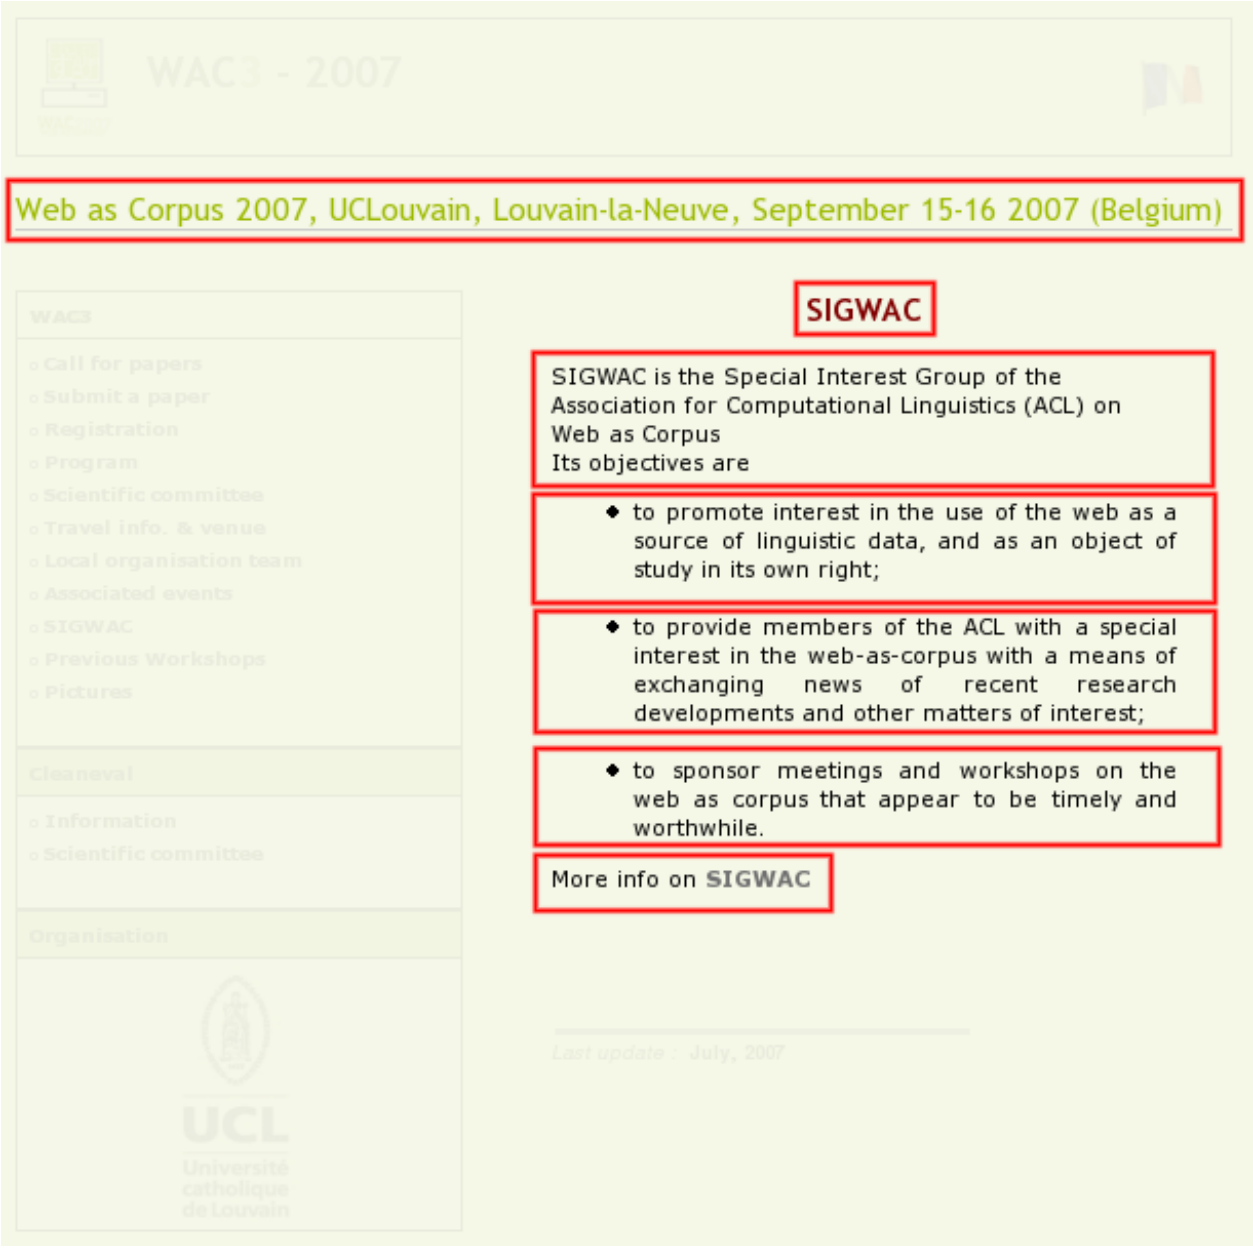

<h>Web as Corpus 2007, UCLouvain, Louvain-la-Neuve, September 15-16 2007 (Belgium)

<h>SIGWAC

<p>SIGWAC is the Special Interest Group of the Association for Computational Linguistics (ACL) on Web as Corpus Its objectives are

<l>to promote interest in the use of the web as a source of linguistic data, and as an object of study in its own right;

<l>to provide members of the ACL with a special interest in the web-as-corpus with a means of exchanging news of recent research developments and other matters of interest;

<l>to sponsor meetings and workshops on the web as corpus that appear to be timely and worthwhile.

<p>More info on SIGWAC

Příklad

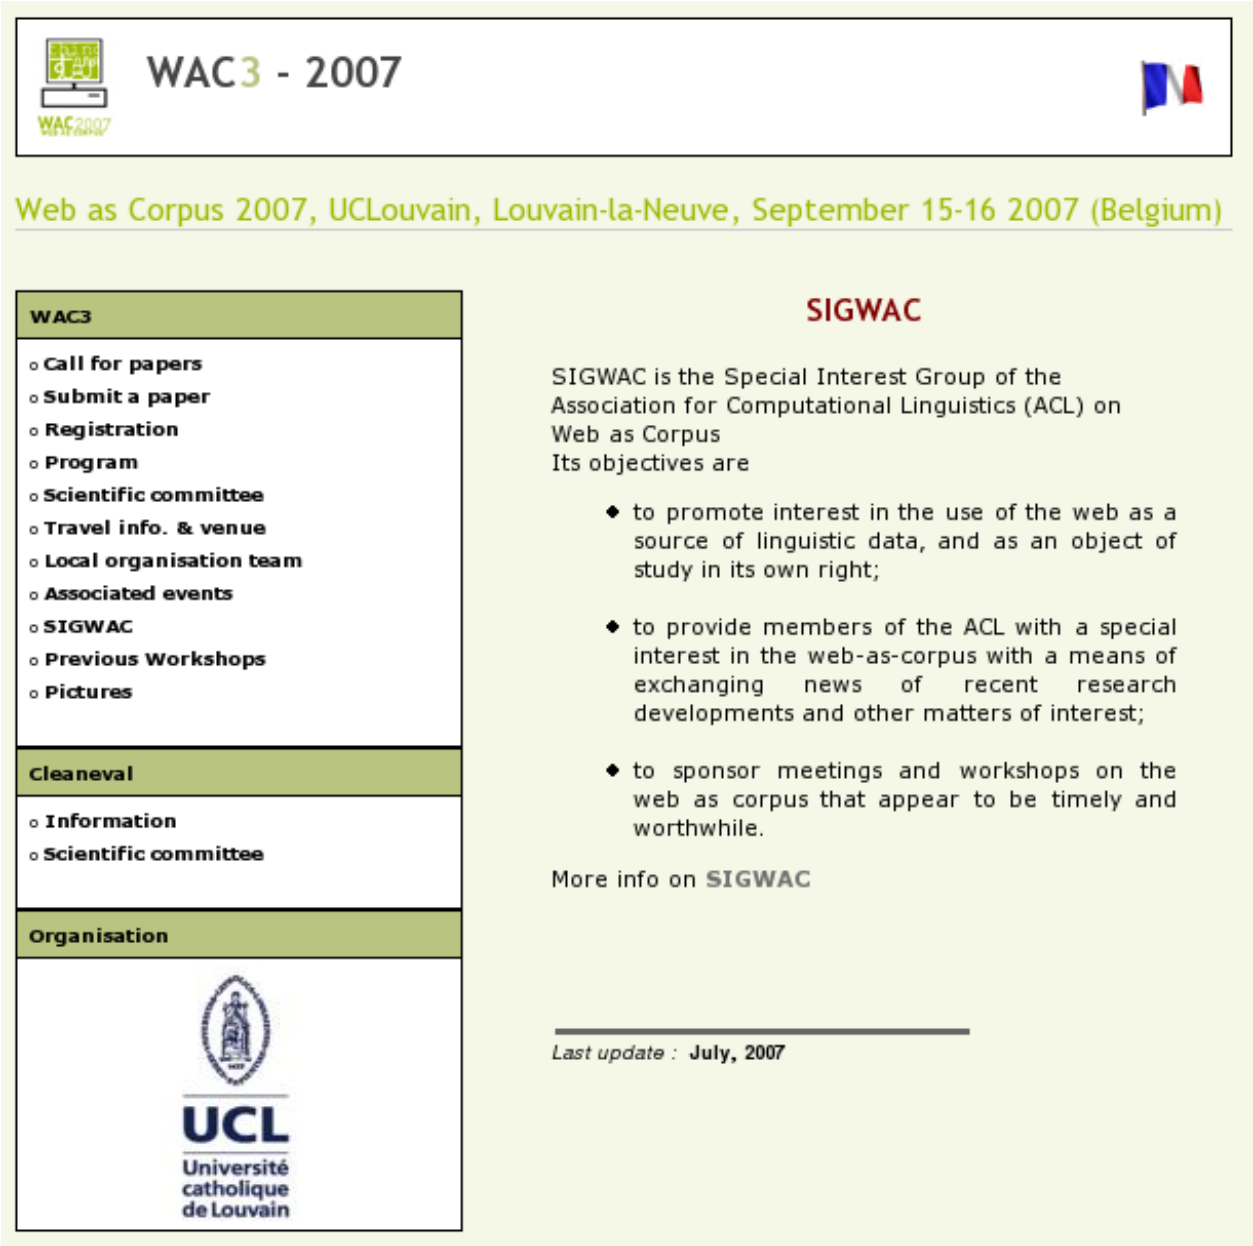

WAC3 - 2007

Web as Corpus 2007, UCLouvain, Louvain-la-Neuve, September 15-16 2007 (Belgium)

WAC3

- Call for papers
- Submit a paper
- Registration
- Program
- Scientific committee
- Travel info. & venue
- Local organisation team
- Associated events
- SIGWAC
- Previous Workshops
- Pictures

Cleaneval

- Information
- Scientific committee

Organisation

UCL Université catholique de Louvain

SIGWAC

SIGWAC is the Special Interest Group of the Association for Computational Linguistics (ACL) on Web as Corpus
Its objectives are

- to promote interest in the use of the web as a source of linguistic data, and as an object of study in its own right;
- to provide members of the ACL with a special interest in the web-as-corpus with a means of exchanging news of recent research developments and other matters of interest;
- to sponsor meetings and workshops on the web as corpus that appear to be timely and worthwhile.

More info on SIGWAC

Last update : **July, 2007**

<h>Web as Corpus 2007, UCLouvain, Louvain-la-Neuve, September 15-16 2007 (Belgium)

<h>SIGWAC

<p>SIGWAC is the Special Interest Group of the Association for Computational Linguistics (ACL) on Web as Corpus Its objectives are

<l>to promote interest in the use of the web as a source of linguistic data, and as an object of study in its own right;

<l>to provide members of the ACL with a special interest in the web-as-corpus with a means of exchanging news of recent research developments and other matters of interest;

<l>to sponsor meetings and workshops on the web as corpus that appear to be timely and worthwhile.

<p>More info on SIGWAC

Jak na to . . .

1. vstupní HTML soubor je pomocí utilitky Tidy převeden do validního XHTML
2. validní dokument je automaticky zbaven skriptů a stylů
3. dokument je parsován a rozdělen do textových bloků oddělených HTML značkami
4. pro každý blok jsou extrahovány hodnoty rysů, které popisují jeho "*kvalitu*"
5. na základě hodnot rysů svých a okolních bloků je každý blok klasifikován (označen) jednou z následujících značek (*sequence labeling*):
   - <h>,<p>,<l> - *nadpis, odstavec, položka seznamu*
   - <c> - *pokračování nadpisu, odstavce, nebo položky seznamu*
   - <o> - *ostatní*
6. bloky označené <h>,<p>,<l> zůstávají v textu a jsou jim předřazeny jejich značky
7. bloky označené <c> zůstávají v textu tak, jak jsou
8. bloky označené <o> jsou odstraněny

Příklad

Krok 0: Vstupní HTML soubor

```
<html>
<head>
<title>Sample Web Page</title>
<style> body  color:  green;  </style>
</head>
<body>
<h1>Hello World!</h1>
<p>This is a simple webpage made of a paragraph and a list.</p>
<ul>
<li>It has <b>bold</b> fonts.
<li>And <i>italic</i>, too.
</ul>
<p><a href="mailto:mail@example.org">contact</a>
</body>
</html>
```

Příklad

Krok 1: Normalizace pomocí Tidy

```
<html>
<head>
<title>Sample Web Page</title>
<style> body  color:  green;  </style>
</head>
<body>
<h1>Hello World!</h1>
<p>This is a simple webpage made of a paragraph and a list.</p>
<ul>
<li>It has <b>bold</b> fonts.</li>
<li>And <i>italic</i>, too.</li>
</ul>
<p><a href="mailto:mail@example.org">contact</a></p>
</body>
</html>
```

Příklad

Krok 2: Odstranění skriptu

```
<html>
<head>
<title>Sample Web Page</title>
<style> body  color:  green;  </style>
</head>
<body>
<h1>Hello World!</h1>
<p>This is a simple webpage made of a paragraph and a list.</p>
<ul>
<li>It has <b>bold</b> fonts.</li>
<li>And <i>italic</i>, too.</li>
</ul>
<p><a href="mailto:mail@example.org">contact</a></p>
</body>
</html>
```

Příklad

Krok 3: Identifikace textových bloků

```
<html>
<head>
<title>Sample Web Page</title>
<style> body  color:  green;  </style>
</head>
<body>
<h1>Hello World!</h1>
<p>This is a simple webpage made of a paragraph and a list.</p>
<ul>
<li>It has <b>bold</b> fonts.</li>
<li>And <i>italic</i>, too.</li>
</ul>
<p><a href="mailto:mail@example.org">contact</a></p>
</body>
</html>
```

Příklad

Krok 4: Získání hodnot rysů

```
<html>
<head>
<title>Sample Web Page</title>
<style> body  color:  green;  </style>
</head>
<body>
<h1>Hello World!</h1>
<p>This is a simple webpage made of a paragraph and a list.</p>
<ul>
<li>It has <b>bold</b> fonts.</li>
<li>And <i>italic</i>, too.</li>
</ul>
<p><a href="mailto:mail@example.org">contact</a></p>
</body>
</html>
```

Příklad

Krok 5: Značkování

```
<html>
<head>
<title>Sample Web Page</title>
<style> body  color:  gReen;  </style>
</head>
<body>
<h1>Hello World!</h1>
<p>This is a simple webpage made of a paragraph and a list.</p>
<ul>
<li>It has <b>bold</b> fonts.</li>
<li>And <i>italic</i>, too.</li>
</ul>
<p><a href="mailto:mail@example.org">contact</a></p>
</body>
</html>
```

Příklad

Krok 5: Značkování

```
<html>
<head>
<title><h>Sample Web Page</title>
<style> body  color:  gReen;  </style>
</head>
<body>
<h1> <h>Hello World!</h1>
<p> <p>This is a simple webpage made of a paragraph and a list.</p>
<ul>
<li> <l>It has  <b> <c>bold</b>  <c>fonts.</li>
<li> <l>And  <i> <c>italic</i> <c>, too.</li>
</ul>
<p><a href="mailto:mail@example.org"> <o>contact</a></p>
</body>
</html>
```

Příklad

Krok 6: bloky <h>,<p>,<l>

```
<html>
<head>
<title><h>Sample Web Page</title>
<style> body  color:  gReen;  </style>
</head>
<body>
<h1> <h>Hello World!</h1>
<p> <p>This is a simple webpage made of a paragraph and a list.</p>
<ul>
<li> <l>It has  <b> <c>bold</b>  <c>fonts.</li>
<li> <l>And  <i> <c>italic</i> <c>, too.</li>
</ul>
<p><a href="mailto:mail@example.org"> <o>contact</a></p>
</body>
</html>
```

Příklad

Krok 7: bloky <c>

```
<html>
<head>
<title><h>Sample Web Page</title>
<style> body  color:  gReen;  </style>
</head>
<body>
<h1> <h>Hello World!</h1>
<p> <p>This is a simple webpage made of a paragraph and a list.</p>
<ul>
<li> <l>It has  <b>  bold  </b>  fonts.</li>
<li> <l>And  <i>  italic, too.</li>
</ul>
<p><a href="mailto:mail@example.org"><o>contact</a></p>
</body>
</html>
```

Příklad

Krok 8: bloky <o>

```
<html>
<head>
<title><h>Sample Web Page</title>
<style> body  color:  gReen;  </style>
</head>
<body>
<h1> <h>Hello World!</h1>
<p> <p>This is a simple webpage made of a paragraph and a list.</p>
<ul>
<li> <l>It has  <b>  bold  </b>  fonts.</li>
<li> <l>And  <i>  italic, too.</li>
</ul>
<p><a href="mailto:mail@example.org">contact</a></p>
</body>
</html>
```

Příklad

Krok 9: Hotovo

```
<h>Sample Web Page



<h>Hello World!
<p>This is a simple webpage made of a paragraph and a list.

<l>It has bold fonts.
<l>And italic, too.
```

Příklad

Krok 9: Hotovo

```
<h>Sample Web Page
<h>Hello World!
<p>This is a simple webpage made of a paragraph and a list.
<l>It has bold fonts.
<l>And italic, too.
```

Typy rysů a jejich příklady

“Content-based”

- délka textu v bloku – počty znaků, slov, vět, odstavců
- rozdělení výskytu vybraných znaků (alfabetické, numerické, zvláštní . . .)
- rozdělení výskytu vybraných řetězců (slova, neslova, URL, čísla . . .)

“Markup-based”

- typy a počty HTML značek, do kterých je blok uzavřen
- typy a počty HTML značek, které oddělují blok od *předchozího* bloku
- typy a počty HTML značek, které oddělují blok od *následujícího* bloku

“Document-based”

- relativní a absolutní poloha bloku v dokumentu (povrchová, v HTML struktuře)
- počet výskytu stejných bloků v dokumentu
- délka dokumentu – počty znaků, slov, vět, odstavců
- parametry rozdělení délek bloků dokumentu

Značkování sekvencí (*sequence labeling*)

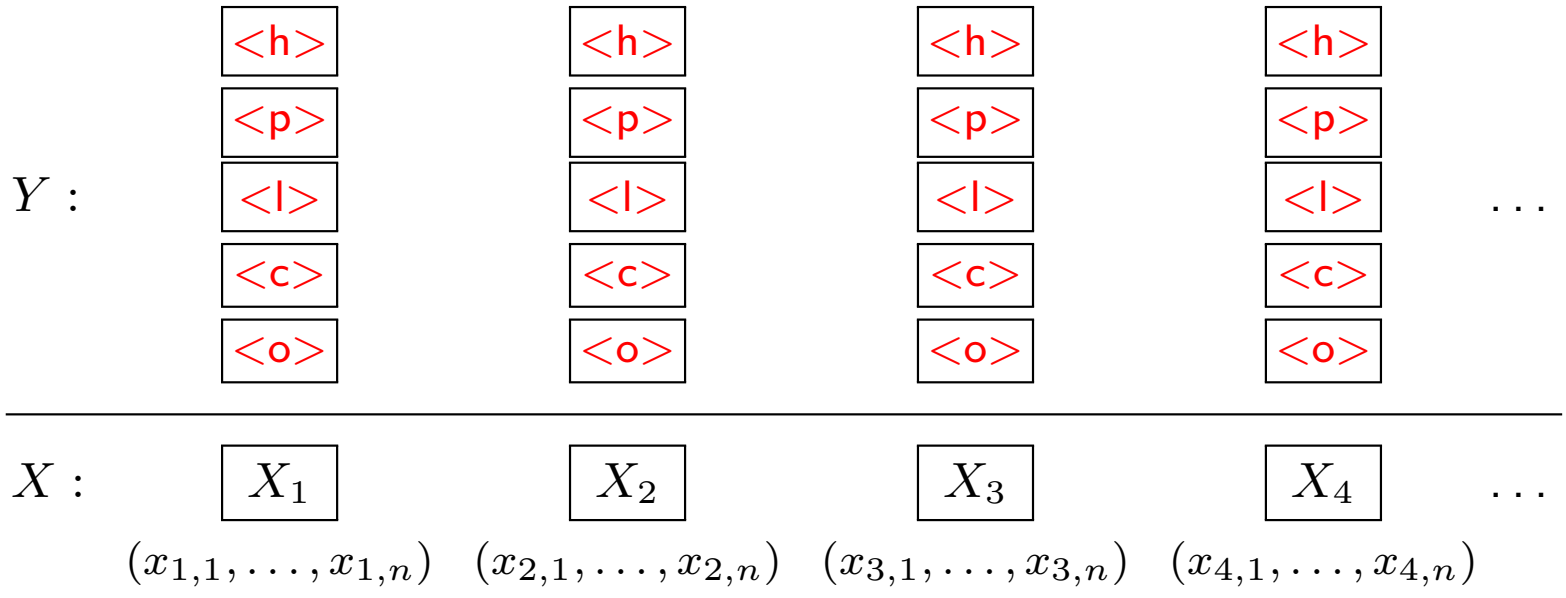

X: sekvence textových bloků $X_1, \ldots, X_N$
Y: sekvence značek $Y_1, \ldots, Y_N$

Značkování sekvencí (*sequence labeling*)

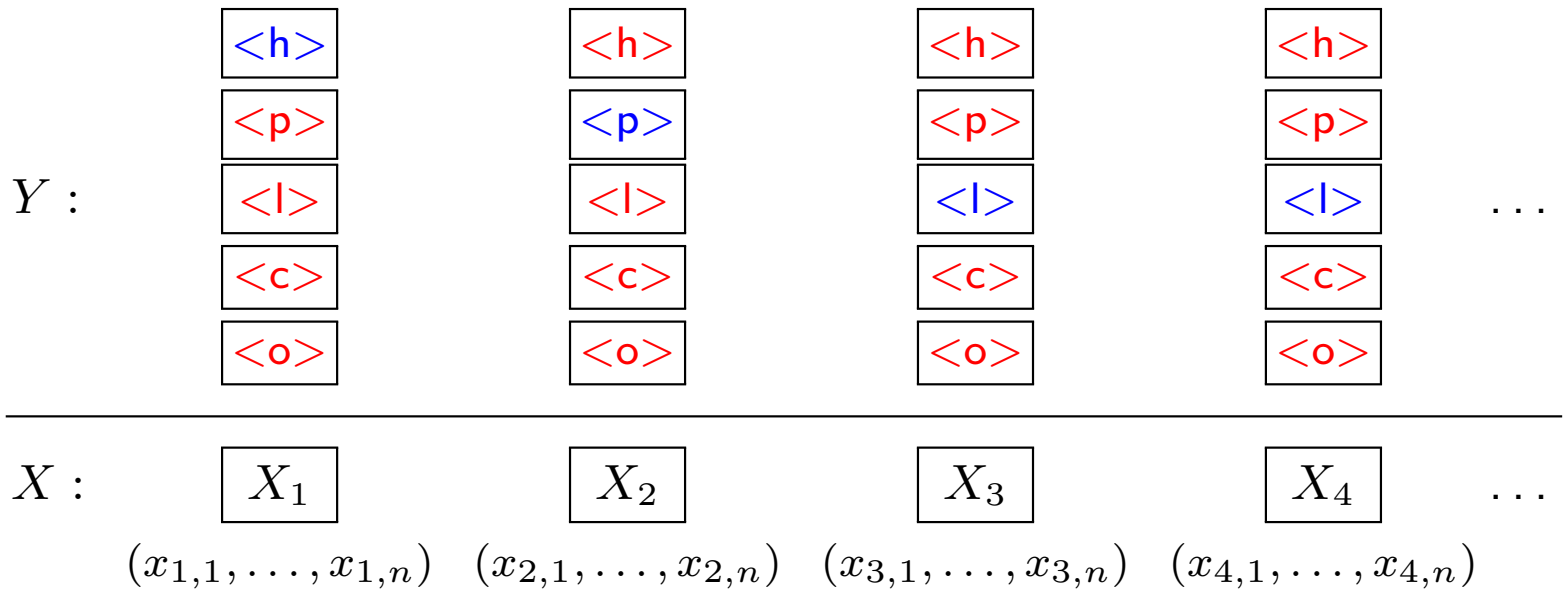

X: sekvence textových bloků $X_1, \ldots, X_N$
Y: sekvence značek $Y_1, \ldots, Y_N$

Značkování sekvencí (*sequence labeling*)

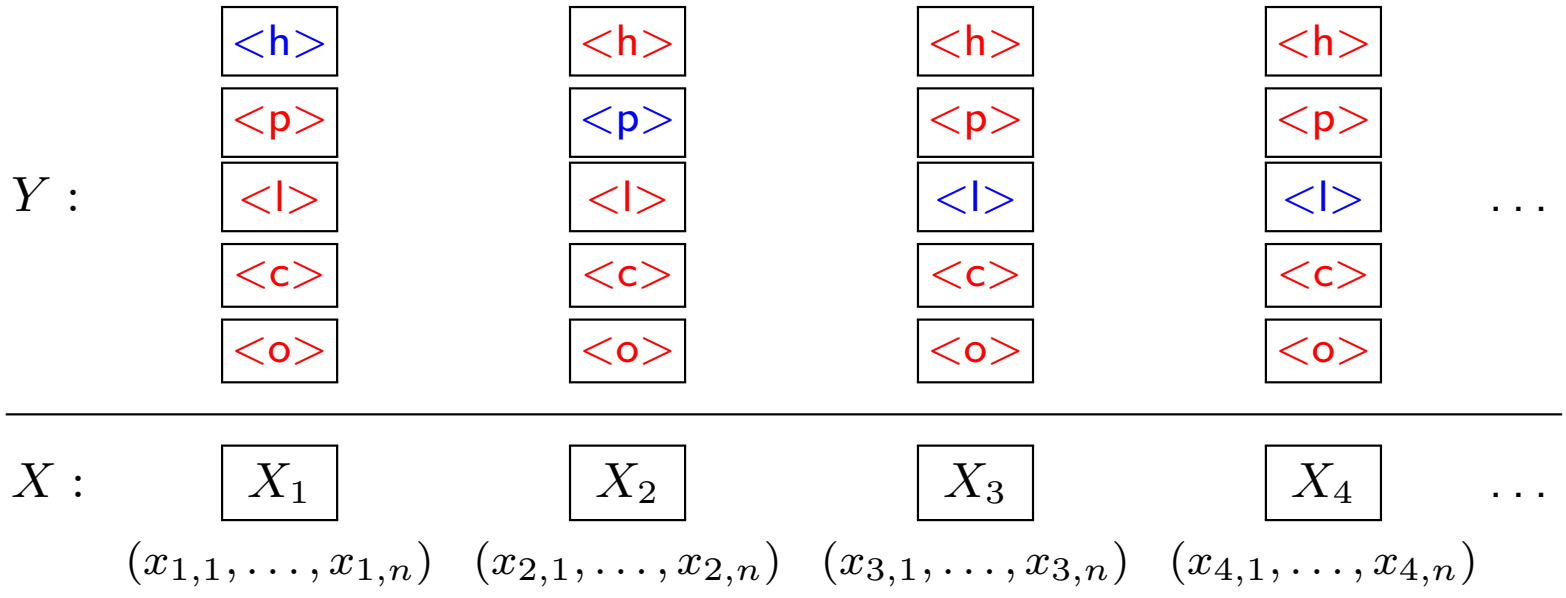

X: sekvence textových bloků $X_1, \ldots, X_N$
Y: sekvence značek $Y_1, \ldots, Y_N$

- Klasifikace: $p(Y_i|X_i)$
- Hidden Markov Models: $p(Y_i|X_i, X_{i-1})$
- Conditional Random Fields: $p(Y_i|X)$

Experimenty

Data

- 104 náhodně vybraných anglických www stránek segmentováno na textové bloky a anotováno
- o každém bloku bylo rozhodnuto, zda má být odstraněn, případně jakou značku mu přiřadit
- soubory rozděleny do 6 stejně velkých podmnožin

label	count
header	1 996
paragraph	3 419
list item	1 149
continuation	3 380
total (*content*)	9 944
other (*noise*)	12 557

Výsledky

- pomocí krosvalidace odhadnut podíl úspěšně označených bloků textu
- trénováno vždy na 5 dílech, testováno na 1, výsledky zprůměrovány

	full label set	content-noise
Exp-1	74.45	82.60
Exp-2	75.09	83.09
Exp-3	75.01	82.88

Cleaneval 2007

Soutěž v čištění webových stránek

"A shared task and competitive evaluation on the topic of cleaning arbitrary web pages, with the goal of preparing web data for use as a corpus, for linguistic and language technology research and development."

Organizátoři

Marco Baroni (*University of Trento*), Serge Sharoff (*Leeds University*)
Francis Chantree, Adam Kilgarriff (*Lexical Computing Ltd*)

Průběh

- zveřejněna data pro vývojové účely včetně evaluačního skriptu (*březen*)
- evaluační data připravena pro účastníky, výsledky (vyčištěné dokumenty) musí být odeslány zpět do 24 hodin po jejich přijetí(*červen*)
- vyhodnocování výsledků organizátory (*červenec*)
- příprava příspěvků na workshop (*srpen*)
- workshop, prezentace příspěvků, vyhlášení vítězů a analýza výsledků (*září*)

Cleaneval 2007: detaily

Příprava dat

- náhodný výběr z již existujícího anglického webového korpusu
- manuální čištění provádělo 23 anotátorů
- 57 stránek, včetně vyčištěné podoby určeno pro vývoj a ladění metod
- 653 stránek pro testování (vyčištěnou podobu soutěžící neviděli)

Evaluační skript

- vstup:- *soubor vyčištěný automaticky (od soutěžícího týmu)*
  - *soubor vyčištěný ručně (anotovaný)*
- normalizace: - *převod na malá písmena*
  - *odstranění interpunkce*
  - *vertikalizace (jedno slovo na řádek)*
- evaluační míra: - *založená na editační vzdálenosti (Levenstein)*
  - *substituce se penalizuje dvojnásobně*
- dva režimy: - *značky se berou v úvahu (Markup+Text)*
  - *značky se ignorují (Text-only)*

Účastníci

- 9 týmů
- 7 zemí
- 4 světadíly

Team
Charles University, *Czech Republic*
Elhuyar Foundation, *Spain*
University of Amsterdam, *Netherlands*
IRST Center, *Italy*
GenieNows *Canada*
Osnabrück University, *Germany*
Chaudhury University, *India*
Osnabrück University, *Germany*
North West University, *South Africa*

Účastníci a výsledky

- 9 týmů
- 7 zemí
- 4 světadíly

Team	Text+Markup	Text-Only	Average
Charles University, *Czech Republic*	65.3	84.1	**74.7**
Elhuyar Foundation, *Spain*	65.3	83.4	74.3
University of Amsterdam, *Netherlands*	65.5	83.0	74.2
IRST Center, *Italy*	65.6	82.5	74.0
GenieNows *Canada*	63.9	83.4	73.6
Osnabrück University, *Germany*	60.3	82.9	71.6
Chaudhury University, *India*	59.5	80.9	70.2
Osnabrück University, *Germany*	53.5	73.5	63.5
North West University, *South Africa*	45.5	60.2	52.9

Další kroky

- vylepšit systém použitím jiných/lepších rysů
- natrénovat systém pro čištění stránek v češtine
- využít systém pro vytvoření velkého českého webového korpusu

Otázky a odpovědi

Děkuji za pozornost.