# Zásady rekonštrukcie textov

**Robert Nádvorník – Róbert Sabo**

*Materiál nebol publikovaný, je len na interné použitie*

**Postup pri prevádzaní tlačeného textu do elektronickej podoby:**

naskenovanie publikácie → .tif súbor → rozpoznanie textu → .rtf súbor → kontrola a korekcia textu v textovom editore → .sxw súbor (OpenOffice formát)

Pri kontrole a korekcii textu dodržiavame konvenciu 1 : 1, t. j. v naskenovanom texte opravujeme iba chyby vzniknuté nekorektným rozpoznaním. Preklepy a iné chyby, ktoré sa vyskytujú v pôvodnom tlačenom texte, rekonštruujeme tak, ako boli vytlačené.

**Konvencia pomenovania súborov:**

!Súbory sa v zásade nepremenovávajú.
Ak je už text opravený pridá sa za pôvodný názov súboru dátum ukončenia korektúry a slovo final.

Príklad:
george.tif → george.rtf → george-2004-06-02-final.sxw
Ak je pôvodný text rozdelený do viacerých súborov, postup je takýto:
gandhi1.tif, gandhi2.tif, ... → gandhi1.rtf, gandhi2.rtf, ... → gandhi-2004-06-02-final

**Značky používané pri korekcii textov:**

Nadpis: <h1>*text nadpisu*</h1>

Obrázok: <picture>*text*</picture>

alebo

<picture>
*text*
</picture>

Touto značkou sa označujú rôzne obrázky, grafy, fotografie…

Text je text, ktorý bol: v rámci obrázku, názov obrázku pod ním
alebo jeho popis.
Ak je obrázok bez textu, tak ho jednoducho označíme
<picture></picture>.

Príklady:

text

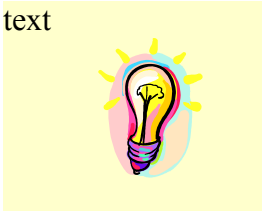

text

text

Tabuľka: <table>*text*</table>

alebo

<table>
*text*
</table>

Touto značkou sa označujú tabuľky, zoznamy...

Príklady:

| | |
|---|---|
| M. Polák | 20 ks |
| P. Veľký | 5 ks |
| M. Malý | 15 ks |

| Názov | | |
|---|---|---|
| txt1 | txt2 | txt3 |
| txt4 | txt5 | txt6 |
| txt7 | txt8 | txt9 |

<table>
M. Polák 20 ks
P. Veľký 5 ks
M. Malý 15 ks
</table>

<table>
Názov
txt1 txt2 txt3
txt4 txt5 txt6
txt7 txt8 txt9
</table>

Po oskenovaní sa opravou tabuľky už ďalej nezaoberáme. Dôležité je len označenie začiatku a konca tabuľky.

Poznámka pod čiarou: \footnote{*text*}

Príklad:
Kľúčovým slovom je tu blackwhite*.
…
*V spisovnej angličtine black — čierny, white — biely, poznámka prekladateľa.

Kľúčovým slovom je tu blackwhite\footnote{V spisovnej angličtine black — čierny, white — biely, poznámka prekladateľa.}.

Súvislý inojazyčný text: <lang *kód krajiny*>*text*</lang>

<lang *kód krajiny*>

*text*
</lang>

| kód krajiny: | Angličtina | EN |
|---|---|---|
| | Čeština | CS |
| | Francúzština | FR |
| | Nemčina | DE |

Príklad:
<lang EN>This is continual English text.</lang>

Neidentifikovateľný text: <noise/>
Takto sa označuje poškodený/nečitateľný text.

**Ďalšie poznámky:**

- V opravovanom dokumente nezáleží na veľkosti písma a type fontu, t. j. časť textu môže byť v Times Roman a časť v Arial a podobne.
- Netreba dodržiavať zarovnanie textu (vľavo, na stred...)
- Treba dávať pozor na automatické odrážky ako: 1.
  2.
  alebo •. Nesmie to byť automatická odrážka. Rozlíšiť sa to dá tak, že je podfarbená šedo alebo sa nedá predňu presunúť kurzor.
- Zvýraznené písmo (kurzíva, tučné, podčiarknutie) sa ponecháva v súlade s originálom. Ak je zvýraznený text napríklad nadpisom, tak zvýraznený bude len text nadpisu, nie značky <h1></h1>. Napr. <h1>**1. kapitola**</h1>
- Treba rozoznávať rôzne typy úvodzoviek: “ ” „ “ „ ” ‘ ’ , ‘ , ‘ a pod.
- Na zápis znakov gréckej, ruskej... abecedy a iných znakov sa pokiaľ možno používajú Unicode znaky.
- Treba rozoznávať pomlčku a spojovník: spojovník –
  pomlčka — (U+2014)
  Tieto znaky opravíme na také, aké boli v pôvodnom texte.
- V texte sa nesmie vyskytovať znak tabelátora.
- Matematické (chemické a iné) vzorce nahradíme tagom <equation/>.
- 
- Horné a dolné indexy:

  Ak je horný alebo dolný index číselný, treba používať zodpovedajúce Unicode znaky, teda $^{01234}_{01234}$. Možnosť nastavenia indexov cez formátovanie písma v textovom editore sa používa len pre nečíselné indexy, napr. „Kapitola I$^{vá}$“

## Skenovanie periodík Sme, Smena, Práca, Pravda

Záhlavie jednotlivých článkov:

ZDROJ: Názov periodika; číslo strany
DATUM: 19941231 (teda RokMesiacDen)
RUBRIKA: napr. Titulka
Spravodajstvo
Zo sveta
Kultúra
Šport
Názory
Ekonomika
Publicistika
(názov rubriky je uvedený v paginácii každej strany)
NAZOV: Názov článku
AUTOR: Meno autora alebo jeho skratka

Tabuľky sa nerobia, do tagov <table></table> sa uvedie len názov tabuľky

Podrubriky a podnadpisy sa označujú hviezdičkou na začiatku riadku.

Príklad:

RUBRIKA: Spravodajstvo
*Stalo sa

!!!Každý článok sa ukladá do samostatného súboru s menom:

ZDROJ_DATUM_RUBRIKA_Cislo strany_Poradove cislo clanku na strane_Srdiečka

| | |
|---|---|
| Jedno srdiečko | a |
| Dve srdiečka | b |
| Na nedeľu | c |
| Ani jedno srdiečko | d |

Príklad:

ZDROJ: SME; s. 3
DATUM: 19990301
RUBRIKA: Spravodajstvo
NAZOV: Bulharských skialpinistov v Tatrách strhla lavína, lyžiarom robil problémy ťažký sneh na zjazdovkách
AUTOR: SME

Názov súboru bude: SME_19990301_Spravodajstvo_03_01_a.sxw

## REKONŠTRUKCIA DOKUMENTOV PÍSANÝCH PÍSCÍM STROJOM

Každý dokument sa ukladá ako samostatný súbor. Napr. každá jedna zápisnica je jeden súbor. Ak je k nej priložená aj prezenčná listina, uvedie sa na konci ako tabuľka. Napr.:

<h1>Zápisnica</h1>

{text zápisnice}

<h1>Prezenčná listina</h1>

<table></table>

Ak je v dokumente text dodatočne opravovaný perom, túto opravu ignorujeme a držíme sa textu, ktorý je písaný písacím strojom. Ak je ale text opravený písacím strojom, teda ak je zlé písmenko nahradené (resp. preklepnuté) správnym, tak zachytávame správnu, upravenú podobu.

Podpisy a pečiatky ignorujeme.
Ak je napríklad nadpis zvýraznený nadpis tak, že sú medzi jednotlivými písmenami medzery, tieto odstraňujeme. Napr. text

Z Á P I S N I C A

rekonštruujeme ako: <h1>ZÁPISNICA</h1>

Ak je text podčiarknutý podčiarknutie dodržujeme.

Tam kde je prečítaná číslovka 1 ako l, opravíme ju na číslo 1 podobne je často prečítaná 0 ako O, tu opravujeme tiež na správny znak..

V celom texte používame značku spojovníka - .