



“Anyone who would letterspace the lowercase  
would steal sheep.”  
*Frederick Goudy (1894–1945)*

“You cannot *not* communicate”  
*Paul Watzlawick (1921– )*

Lidé komunikují prostřednictvím dokumentů  
připravovaných elektronicky

# PB029 Elektronická příprava dokumentů

Petr Sojka

Fakulta informatiky  
MU, Brno

podzim 2013

# Digitální revoluce a její důsledky pro černé řemeslo

- ☞ Digitální revoluce koncem sedmdesátých let.

“Mathematics books and journals do not look as beautiful as they used to.”

*Donald Ervin Knuth*

- ☞ Počítač: od imitace psacího stroje po *sázecí* systém DTP.
- ☞ Typografie matematiky, matematika/informatika slouží typografii: místo metalurgie *informatika*, matematický popis křivek (kubické splajny v programu pro návrh písem METAFONT).

# Digitální revoluce a její důsledky pro černé řemeslo (cont.)

“Go forth and create *masterpieces of electronic publishing art.*”  
(*paraphrase of Donald Knuth [TEXbook, p. 303]*)

# Sázecí systémy

“GUIs normally make it simple to accomplish simple actions and impossible to accomplish complex actions.”

*Doug Gwyn*

- ☞ **Sazba**: realizace návrhu nad značkovanými daty.
- ☞ WYSIWYG (WYSIAWYG): InDesign, Pagemaker (**Adobe**), QuarkXpress (**Quark**), 3B2 (**Advent Publishing**).
- ☞ Dávkové systémy: **T<sub>E</sub>X**, troff/groff/nroff/runoff, **Lout** (nutnost kontroly návrhu dokumentů ve *finální* podobě, ne jen na obrazovce).
- ☞ Textové procesory Word, AmiPro, ... sem de facto nepatří (nedovedou některé docela zásadní potřeby sazeče – nedělitelná roztažitelná mezera, fixace zlomu pro různá výstupní zařízení apod.).

# Programování sazby – T<sub>E</sub>X

## ☞ Algoritmy počítačové sazby v sázecím systému T<sub>E</sub>X

- ① Zlom řádků.
- ② Zlom stránky.
- ③ Dělení slov.
- ④ Umisťování obrázků, viditelnost.
- ⑤ Umisťování poznámek pod čarou.
- ⑥ Sazba matematických výrazů:

$$\sqrt{\left(\int_0^{\infty} \sqrt{\frac{x^2}{2} + 1}\right)}$$

# Programování sazby – T<sub>E</sub>X (cont.)

- ☞ `$$\sqrt{\left(\int_0^{\infty} \sqrt{\frac{x^2}{2}}+1\right)}$$`
- ☞ (Makro)programování sazby, otevřenost systému.
- ☞ OSS, **CSTUG**, **CTAN**, pros & cons.

# Co je T<sub>E</sub>X?

- ☞ Sázeací autorský systém.
- ☞ Programovatelný, t.j. s vlastním makrojazykem (s vyjadřovací silou Turingova stroje – byl v něm například pro zábavu implementován interpret jazyka BASIC); výhoda pro cca 2% populace.
- ☞ Dávkový: ze vstupu  $\$c=\sqrt{a^2+b^2}\$$  dostaneme  $c = \sqrt{a^2 + b^2}$ : <http://tex.mendelu.cz>, <http://sciencesoft.at/index.jsp?link=latex>.
- ☞ Otevřený/rozšiřitelný.
- ☞ Portabilní (od Atari či dvoudisketového PC XT po Cray).
- ☞ Stabilní (\$256 za nalezení chyby), verze  $\rightarrow \pi$ .
- ☞ Dobře dokumentovaný (vyšel knižně).
- ☞ Volně šiřitelný (vývoj hrazen granty).
- ☞ S výstupem *nezávislým* na výstupním zařízení.
- ☞ Jednoduchý základ pro sazbu: model box, glue, penalty.
- ☞ “A computer program of which a professor of computer science might be proud of” (DEK)



# Co T<sub>E</sub>X není?

- Editor.
- Program na grafiku (na to slouží komplementární program METAFONT přibližně stejné velikosti).
- WYSIWYG (nastavby jako LyX existují).
- Rychle naučitelný (strmější učicí křivka).

# Vznik a vývoj T<sub>E</sub>Xu

- ❑ 1977, korektura *The Art of Computer Programming*.
- ❑ 1978, první verze; T<sub>E</sub>X82, METAFONT84; osmibitový T<sub>E</sub>X 3 (1990); rozšiřování o výstupní formáty (PostScript).
- ❑ 1992: zmrazení dalšího vývoje, pevný bod, jen opravy chyb.
- ❑ Vznik makrobalíků.
- ❑ Téměř žádný marketing, uživatelé sdružuje TUG a lokální sdružení uživatelů – LUG.

# T<sub>E</sub>X dnes: pro klasickou publikační činnost

- ❑ Zejména pro matematiku a všude tam, kde je možná algoritmizace zpracování (\$\$).
- ❑ Velká nakladatelství technické literatury a časopisů Springer-Verlag, Elsevier Publishers, Kluwer sází v T<sub>E</sub>Xu časopisy, sborníky.
- ❑ Databázové publikování: Dopravní podnik města Brna (tabulky jízdních řádů pro zastávky, řidiče, dispečery), rozvrhy FI MU, studijní program FI MU přímo z databáze informačního systému MU.
- ❑ Slovníky (LEDA) a první díl encyklopedie (Diderot).
- ❑ Jádro T<sub>E</sub>Xu či jeho algoritmy v sázecích systémech 3B2, InDesign, troff, Lout či v textovém procesoru Word.

# T<sub>E</sub>X dnes I: PDF

- ❑ Nový formát pro elektronické knihy firmy Adobe.
- ❑ Otevřenost T<sub>E</sub>Xu: pdfT<sub>E</sub>X Hàn Thế Thành.
- ❑ Kalkulačka v PDF (+JavaScript): dříve než Adobe.
- ❑ AcroT<sub>E</sub>X.
- ❑ PDF není až tak portabilní jak říká název – místo pro DVI3?

# T<sub>E</sub>X dnes II: Internet (HTML/XML/MATHML)

- ❑ HyperT<sub>E</sub>X ([Los Alamos archiv](#)).
- ❑ [L<sup>A</sup>T<sub>E</sub>X2HTML](#), konvertor z neznámějšího makrobalíku do HTML v Perlu.
- ❑ T<sub>E</sub>X4ht, nebo jiné mnohé komerční implementace T<sub>E</sub>Xu s alternativním výstupem do HTML jako [T<sub>E</sub>Xpider](#) (MicroPress).
- ❑ eeT<sub>E</sub>X (pro přímou sazbu SGML).
- ❑ [TTH](#): konvertor T<sub>E</sub>Xu do HTML.
- ❑ [IBM techplorer Hypermedia Browser](#) – plug-in do Netscape a Internet Exploreru.
- ❑ [MathType](#) pro psaní matematiky ve Windows.

# T<sub>E</sub>X dnes II: Internet (HTML/XML/MATHML) (cont.)

- ❑ **T<sub>E</sub>XML** (Doug Lovell, IBM): XML reprezentace T<sub>E</sub>Xové syntaxe.
- ❑ **WebEQ**: sada programů včetně Javovského apletu pro rastrování matematiky.
- ❑ **Texi2html**: konverze Texinfo formátu do html.
- ❑ **Word2TeX**: konfigurovatelný konvertor z rozšířeného měnicího se formátu do stabilního.
- ❑ **ASTER** systém pro čtení L<sup>A</sup>T<sub>E</sub>Xového zápisu a dokumentů pro nevidomé
- ❑ a mnoho dalších ...

# T<sub>E</sub>X dnes III: Java, Unicode, OpenType

- ❑ NTS: reimplementace T<sub>E</sub>Xu bez optimalizací v Javě (Karel Skoupý, FI MU, nyní ÚVT MU), a následný výzkum.
- ❑ PDF prohlížeč v Javě → vysoce portabilní prvotřídně vysazené dokumenty s minimem přenosu dat v dohledu.
- ❑ Omega: mnohem více než šestnáctibitový T<sub>E</sub>X; konverze L<sup>A</sup>T<sub>E</sub>Xu do MathML.
- ❑ PATLIB, opatgen, upatgen, ...
- ❑ XeT<sub>E</sub>X, viz sobotní přednáška CSTUG.

# Perspektivy T<sub>E</sub>Xu a jeho následníků v tomto tisíciletí

- ❑ T<sub>E</sub>X pevný bod v chaosu postmoderního světa?
- ❑ Interaktivní dokumenty: otevřenost umožňuje rychle reagovat na nové formáty a standardy.
- ❑ Rozšiřování požadavků na **autorské** systémy.
- ❑ Bude se opakovat historie s tím, že v T<sub>E</sub>Xové komunitě navržené a vyzkoumané postupy, algoritmy a přístupy se stanou základem většiny komerčních aplikací v oblasti DTP?
- ❑ embedded systémy [části] T<sub>E</sub>Xu součástí větších projektů.



# Jak se na to připravit?

- Instalovat si T<sub>E</sub>X a učit se ho:
- učit se, učit se, učit se.
- Stát se členem sdružení CSTUG a účastnit se aktivně jeho akcí a projektů.

# Závěr

“We are all apprentices in a craft  
where no-one ever becomes a master.”  
*Ernest Hemingway*

- ❑ Úcta k tradicím, osvěta.
- ❑ Další studium: [www.sazba.cz](http://www.sazba.cz) (Kapr: Sto a jedna věta o knižní úpravě),  
[www.typo.cz](http://www.typo.cz) (písma, PostScript, . . . ), Beranův [Typografický manuál](#).

“A man who would letterspace lower case would steal sheep.”  
*Frederick Goudy, 1894–1945*

“If this wisdom needs updating, it is chiefly to add that  
*A woman who would . . .*”  
*Robert Bringhurst*

# Sazba – Algoritmy zlomu a formáty písem

- Digitální formáty písem
- Algoritmy zlomu
- hz rozšíření

# Digitální formáty písem

- Formáty METAFONT, PostScript a TrueType (OpenType).
- Princip oddělení metrické informace potřebné při sazbě od informace o tvarech znaků.
- Metrické informace: rozměry jednotlivých znaků, mezipísmenný kerning, ligační programy. Formáty TFM a AFM, program afm2tfm.
- Tvary znaků jsou popsány jako bitmapy (optimalizace znaků pro obrazovku, PostScript Type 3) nebo pomocí křivek obrysů či per. PostScript Type1 používá pro popis obrysů kubické Bézierovy křivky, formát TrueType výpočetně méně náročné kvadratické Bézierovy křivky a METAFONT parametrická pera.

## Digitální formáty písem (cont.)

- Detailní český popis digitálních formátů písem je k nalezení v DP PřířF MU Pavla Janíka a DP FI MU Jana Vidy.

# Algoritmy řádkového a stránkového zlomu

- ☞ Algoritmus First fit: sazba po řádcích, výběr prvního možného zlomu. Nenáročný na výpočetní kapacitu.
- ☞ Algoritmus Best fit: zlom po řádcích, výběr nejlepšího zlomu na řádku bez přihlídnutí k předchozím možnostem. Míra optimality řádku je měřena mírou odchylky od ideální velikosti mezislovní mezery. V  $\text{T}_{\text{E}}\text{X}$ u je míra škaredosti (badness)  $100 \cdot |r|^3$ , kde  $r$  je poměr rozdílu přirozené a požadované délky řádku ku součtu roztažitelných a stlačitelných složek lepidla (glue).

## Algoritmy řádkového a stránkového zlomu (cont.)

- ☞ Algoritmus Optimum fit: optimalizace zlomu v rámci celého odstavce naráz s využitím modelu 'box, glue a penalty'. Úloha podobná hledání nejkratší cesty v grafu, každé cestě odpovídá škaredost, která se minimalizuje. Stačí zvažovat pouze možnosti hezčí než zadaná tolerance.

## Parametry algoritmu řádkového zlomu $\TeX$ u

- Až tři průchody: první bez dělení slov, limit škaredosti je `\pretolerance`. Pak jsou rozdělena všechna slova v odstavci a proveden druhý pokus s limitem škaredosti `\tolerance`.
- Pokud je nastaven registr `\emergencystretch` na kladnou délku (zvětšení roztažitelnosti mezislovní mezery) a jde o  $\TeX$ 3.0 či vyšší, provede se třetí pokus o zlom s těmito limity roztažitelností.
- Další parametry ovlivňující algoritmy zlomu: řádkového: `\adjdemerits`, `\linepenalty`, `\hyphenpenalty`, `\exhyphenpenalty`, `\looseness` a stránkového: `\interlinepenalty`, `\clubpenalty`, `\widowpenalty`, `\brokenpenalty`, ...



# Parametry algoritmu řádkového zlomu T<sub>E</sub>Xu (cont.)

- ☞ Ladění parametrů zlomu pro daný projekt (Diderot).
- ☞ Detailní český popis variant algoritmů zlomu je k nalezení v DP FI MU Jana Pazdziory.

# hz-algoritmus

- ☞ Motivace: Gutenbergova 42řádková Bible měla 290 písmen abecedy proměnné šířky, stejná mezislovní mezera při sazbě do bloku.
- ☞ Principy: kerning, scaling, composing.
- ☞ URW, Karrow, Zapf, neúspěch (fonty).
- ☞ Implementace v pdfT<sub>E</sub>Xu (Thành).
- ☞ Implementace v InDesignu (Karrow).
- ☞ Detailní český popis modifikací zlomového algoritmu písem je k nalezení v DP Mirky Misákové a disertaci Hàn Th<sub>ế</sub> Thànha.

# Implementace algoritmu dělení slov

- ☞ Dizertace a program PatGen Franka Lianga.
- ☞ Princip soutěživých vzorů, nezávislost na jazyce.
- ☞ Vytváření a generování vzorů.
- ☞ OPatGen, knihovna PatLib, upatgen.
- ☞ Detailní popis algoritmu dělení slov je k nalezení v DP FI MU Davida Antoše.

# Principy makroprogramování

- Makrojazyk  $\text{\TeX}$ : složité sázecí postupy skládané z 300 základních příkazů (primitiv).
- (Ne)vhodnost makroprogramování (versus detailní značkování), minimalizace vstupu.
- Input procesor: řádky nezávislé na operačním systému.
- Token procesor.
- Expand procesor.
- Hlavní procesor.
- Detaily v češtině jsou v Olšákové TeXbooku naruby (TBN).

# Makrobalíky

- Znovuobjevování kola většinou není potřeba: tisíce balíků maker na CTAN (Comprehensive T<sub>E</sub>X Archive Network).
- Katalog balíků na CTAN.
- Příklady balíků, kniha L<sup>A</sup>T<sub>E</sub>X Companion.
- DVD s distribucí T<sub>E</sub>Xlive 2013.

# InDesign

- ☞ Komerční program firmy Adobe pro WYSIWYG počítačovou sazbu.
- ☞ Zlomový algoritmus (převzat z  $\text{T}_{\text{E}}\text{X}_{\text{U}}$ ) s pomocí Davida Karrowa (URW).
- ☞ Škálování znaků.
- ☞ Optický proklad (David Kindersley: Optical letter spacing for new printing systems, 1976).
- ☞ Příklady zlomu a chyb.

# Jazyky pro popis stránky

- ☞ PDL – jazyk pro popis stránky, kombinace textu s grafikou.
- ☞ Formát firmy Adobe (Geschke, Warnock, 1982, Apple Laserwriter, Aldus Pagemaker), nyní de facto standard.
- ☞ Linotronic 1986, svět osvitových jednotek (vysoké rozlišení).
- ☞ Vývoj/podpora – Level1, Level2, (Level3).
- ☞ Návazné/odvozené/související produkty/standardy: PDF, písma Type1 (vektorový popis), Type3 (bitmapy).
- ☞ Nově **OpenType**.

# PostScript – vlastnosti jazyka

- ☞ Nezávislost na zařízení (různé rozlišovací schopnosti výstupních zařízení).
- ☞ Souřadné systémy, prostor uživatele, prostor zařízení.
- ☞ Interpreter – PostScriptový RIP, hardwarový nebo softwarový (Ghostscript, Ghostview).
- ☞ Zásobníkový programovací jazyk, postfixový zápis v reverzní polské notaci.
- ☞ Podpora různých barevných prostorů (CMYK, RGB), direktní barvy.
- ☞ Nezávislost na platformě – vytváření/generování PostScriptu aplikacemi.



# PostScript – příklad

```
1  %!PS-Adobe-2.0
2  %%Title: Příklad Postscript programu
3  /Helvetica-Bold findfont
4  50 scalefont setfont
5  0 0 moveto 200 0 lineto
6  200 100 lineto 0 100 lineto
7  closepath 0.8 setgray fill
8  0 setgray
9  30 40 moveto
10 (FI MU)show
11 showpage
```

# PostScript – příklad (cont.)



# Struktura PostScriptového souboru

- ☞ Záhloví, komentář Bounding Box, úrovně PostScriptu (Level).
- ☞ Definice procedur.
- ☞ Nastavení dokumentu.
- ☞ Jednotlivé stránky.
- ☞ Konec dokumentu.

# PostScriptové objekty a jejich zpracování

- Prostor uživatele a prostor zařízení.
- Skládání afinních transformací (CTM, operátory pro modifikaci aktuální matice transformace: rotace, translace, zmenšení/zvětšení).
- Cesty.
- Konstrukce Bézierovy (kubické) křivky.
- Detaily v češtině jsou ve [Zpravodaji CSTUG 1–3/2001](#).

# PDF – vlastnosti

- ☞ *Proprietární* formát firmy Adobe.
- ☞ Objektový *formát*, není to programovací jazyk.
- ☞ Portabilita je dlužná svému jménu :-(. Neportabilní záložky (závisí na systémovém fontu).
- ☞ Binární formát, nelze jednoduše editovat (tabulka xref na konci PDF odkazuje na jednotlivé byty souboru).
- ☞ Struktura PDF, základní objekty, struktura souboru, popis stránky, komprese.
- ☞ Srovnání s DVI, PS.
- ☞ Možnost optimalizovat pro web, možnost vkládat JavaScript přímo do PDF.

# Způsoby vytváření PDF

- ☞ pdfT<sub>E</sub>X!
- ☞ ghostscript: dávka ps2pdf.
- ☞ Adobe Acrobat Distiller.
- ☞ PDF Writer (virtuální tiskárna, minimální optimalizace).
- ☞ Adobe Acrobat Capture (OCR).
- ☞ PStill, ...

# Verze PDF

- ☞ Úrovně jazyka 1.0 až 1.9 pro Acrobat 1 až Acrobat 10. Aktuální specifikace PDF 1.9 má přes tisíc stran.
- ☞ PDF-X: Ořezaná verze jazyka podporovaná ANSI, ISO a firmami v předtiskovém byznysu.
- ☞ PDF-X1, PDF-X2, PDF-X3, maximální spolehlivost při DTP a Prepress workflow (povinnost mít vložené fonty, ...).
- ☞ PDF-A verze pro archivaci skenovaných předloh.
- ☞ PDF-ISO (upravená verze 1.7 schválená institucí ISO)
- ☞ FAQ.